

**SVEUČILIŠTE U SPLITU**  
**EKONOMSKI FAKULTET**

**DIPLOMSKI RAD**

**PRIMJENA BENFORDOVOG ZAKONA U**  
**OTKRIVANJU KOZMETIČKIH**  
**RAČUNOVODSTVENIH MANIPULACIJA**

**Mentor:**

**Izv. prof. dr. sc. Tina Vuko**

**Student:**

**Dino Nimac**

**Matični broj: 2141752**

**Split, kolovoz, 2016.**

## **SADRŽAJ:**

|                                                                    |           |
|--------------------------------------------------------------------|-----------|
| <b>1. UVOD .....</b>                                               | <b>4</b>  |
| <b>1.1. Problem istraživanja .....</b>                             | <b>4</b>  |
| <b>1.2. Predmet istraživanja .....</b>                             | <b>6</b>  |
| <b>1.3. Istraživačke hipoteze i ciljevi istraživanja .....</b>     | <b>7</b>  |
| <b>1.4. Metode istraživanja .....</b>                              | <b>8</b>  |
| <b>1.5. Doprinos istraživanja .....</b>                            | <b>9</b>  |
| <b>1.6. Struktura diplomskog rada .....</b>                        | <b>9</b>  |
| <b>2. SUSTAV FINACIJSKOG IZVJEŠTAVANJA .....</b>                   | <b>11</b> |
| <b>2.1. Temeljni financijski izvještaji .....</b>                  | <b>11</b> |
| <b>2.2. Cilj temeljnih financijskih izvještaja.....</b>            | <b>13</b> |
| <b>2.3. Kvalitativna obilježja financijskih izvještaja .....</b>   | <b>13</b> |
| <b>2.4. Godišnji financijski izvještaji.....</b>                   | <b>14</b> |
| 2.4.1. Izvještaj o financijskom položaju (bilanca).....            | 14        |
| 2.4.2. Račun dobiti i gubitka .....                                | 16        |
| 2.4.3. Izvještaj o novčanom tijeku.....                            | 17        |
| 2.4.4. Bilješke uz financijske izvještaje.....                     | 19        |
| <b>2.5. Korisnici financijskih izvješća .....</b>                  | <b>20</b> |
| <b>3. RAČUNOVODSTVENE MANIPULACIJE .....</b>                       | <b>21</b> |
| <b>3.1. Pojam i obilježja računovodstvenih manipulacija .....</b>  | <b>21</b> |
| <b>3.2. Poticaji, motivi i ciljevi manipuliranja.....</b>          | <b>22</b> |
| <b>3.3. Vrste računovodstvenih manipulacija .....</b>              | <b>24</b> |
| 3.3.1. Manipuliranje zaradama.....                                 | 24        |
| 3.3.2. Ugladivanje trenda zarada .....                             | 25        |
| <b>3.4. Računovodstvo "velike kupke" .....</b>                     | <b>26</b> |
| <b>3.5. Kreativno računovodstvo .....</b>                          | <b>26</b> |
| <b>3.6. Kozmetičke računovodstvene manipulacije.....</b>           | <b>27</b> |
| 3.6.1. Definiranje kozmetičkih računovodstvenih manipulacija ..... | 27        |

|                                                                                                                              |           |
|------------------------------------------------------------------------------------------------------------------------------|-----------|
| 3.6.2. Obilježja kozmetičkih računovodstvenih manipulacija .....                                                             | 28        |
| 3.6.3. Pregled istraživanja vezanih za kozmetičke računovodstvene manipulacije.....                                          | 29        |
| <b>3.7. Prijevale i pogreške u financijskim izvještajima .....</b>                                                           | <b>30</b> |
| <b>4. BENFORDOV ZAKON .....</b>                                                                                              | <b>32</b> |
| 4.1. Otkriće Benfordovog zakona.....                                                                                         | 32        |
| 4.2. Koncept Benfordovog zakona .....                                                                                        | 34        |
| 4.3. Prednosti i nedostaci Benfordovog zakona.....                                                                           | 35        |
| <b>5. ISTRAŽIVANJE KOZMETIČKIH RAČUNOVODSTVENIH<br/>MANIPULACIJA U ZEMLJAMA EU PRIMJENOM BENFORDOVE<br/>ZAKONITOSTI.....</b> | <b>36</b> |
| 5.1. Definiranje uzorka .....                                                                                                | 36        |
| 5.2. Primijenjena metodologija.....                                                                                          | 37        |
| 5.3. Rezultati istraživanja .....                                                                                            | 38        |
| <b>6. ZAKLJUČAK.....</b>                                                                                                     | <b>61</b> |
| <b>SAŽETAK.....</b>                                                                                                          | <b>62</b> |
| <b>SUMMARY .....</b>                                                                                                         | <b>62</b> |
| <b>LITERATURA .....</b>                                                                                                      | <b>63</b> |
| <b>POPIS SLIKA.....</b>                                                                                                      | <b>64</b> |
| <b>POPIS TABLICA.....</b>                                                                                                    | <b>64</b> |
| <b>POPIS GRAFIKONA .....</b>                                                                                                 | <b>66</b> |

# 1. UVOD

## 1.1. Problem istraživanja

Svijest o učincima prijevarnog financijskog izvještavanja je u porastu nakon otkrivanja velikog broja korporativnih skandala koji su bili posljedica računovodstvenih manipulacija s financijskim izvještajima od strane menadžmenta. U tom kontekstu Gulin (2002) ukazuje na dvije vrste manipulacija: (a) manipulacije na financijskim tržištima (često se u literaturi nazivaju i burzovne manipulacije) i (b) manipulacije s financijskim izvještajima (nazivaju se još i računovodstvene manipulacije). Međutim kod korištenja pojma manipulacije treba naglasiti da nisu sve računovodstvene manipulacije ilegalne niti su sve namjerne. Naime menadžment može koristiti različite računovodstvene metode kako bi došao do određenih ciljeva u kratkom roku, a da pri tom ne krši zakon u nijednom aspektu poslovanja, a i može se dogoditi nenamjerno pogrešno financijsko izvještavanje kao posljedica pogrešaka u prikupljanju i obradi podataka ili u primjeni računovodstvenih načela. Zakonodavstva pojedinih zemalja putem zakona ili standarda definiraju koje su to manipulacije ilegalne. Kod definiranja takvih manipulacija i njihovoj zabrani prednjači SAD čiji SEC (Securities and Commission Exchange) određuje koje su to manipulacije ilegalne dok zemlje EU-a putem amandmana na Direktive EU žele ograničiti ilegalne manipulacije s financijskim izvještajima (prema Gulin, 2002:2).

Pojam računovodstvene manipulacije ili manipulacije s financijskim izvještajima predstavljaju namjerno pogrešno prikazivanje iznosa u financijskim izvještajima kako bi se zavaralo same korisnike financijskih izvještaja kao što su primjerice potencijalni ulagači gdje manipulant na umjetan način podižu ili spuštaju cijene vrijednosnih papira ovisno od toga žele li doći do priljeva novca ili do većinskog udjela u vlasništvu ili država gdje je manipulantima u interesu prikazati performanse poduzeća što lošijima kako bi se izbjeglo plaćanje poreza.

Na financijskim tržištima postoji puno mogućnosti manipulacija s financijskim izvještajima no fokus u ovom radu je samo na jedan od njih. Naime, radi se o tzv. "kozmetičkim računovodstvenim manipulacijama" koje nastaju na temelju psihološke pojave zaokruživanja brojeva. U računovodstvu ta pojava se odnosi na zaokruživanje iznosa neto dobiti kako bi se postigle ključne kognitivne referentne točke predstavljene izrazom  $N \times 10^k$ .

Kao jedan od najprikladnijih alata u otkrivanju kozmetičkih računovodstvenih manipulacija je zasigurno Benfordov zakon. Ovaj zakon počiva na činjenici da se određene znamenke u skupovima pojavljuju češće od ostalih. Prema Benfordovom zakonu u skupu brojeva s bazom 10 broj 1 ima najveću vjerojatnost pojavljivanja, odnosno 30,1%, nakon njega slijedi broj 2 s vjerojatnošću od 17,6%, odnosno što je broj veći manja je vjerojatnost njegova pojavljivanja. Tako primjerice broj 9 ima najmanju vjerojatnost pojavljivanja u skupu.

Ovu jako zanimljivu i korisnu činjenicu otkrio je 1881. godine američki astronom Simon Newcomb proučavajući logaritamske funkcije. Nažalost Newcombovo otkriće su ignorirali u njegovo vrijeme. Tek 1938. godine fizičar Frank Benford dolazi do istog otkrića ali proučavajući puno veći skup podataka (čak 20.229 skupina različitih podataka) te je za razliku od Newcomba Benfordov rad bio priznat i po njemu se odnosi koje je odredio zovu Benfordovim zakonom.

Prvi koji je koristio Benfordov zakon kako bi otkrio nepravilnosti u distribuciji neto dobiti bio je škotski matematičar Scott Carslaw 1938. godine. On je utvrdio višak nula i nedostatak devetki na drugom mjestu kod pozitivnih iznosa neto dobiti na primjeru jedne kompanije iz Novog Zelanda. Kao i Carslaw, Thomas (1939) je koristio Benfordov zakon također kako bi otkrio nepravilnosti u distribuciji neto dobiti samo što je on otkrio i obrnuti uzorak, tj. višak devetki i nedostatak nula kod negativnih iznosa neto dobiti. Ovaj fenomen zaokruživanja neto dobiti proširio se po čitavom svijetu što je i potvrđeno 2003. godine nakon istraživanja neto dobiti kompanija iz 18 različitih zemalja koje su proveli Kinnuen i Koskela.

Aktualnost ovakvih istraživanja potvrđuje i nedavno objavljeno istraživanje koje su proveli Stojanović i Borowiecki (2015) na listanim Europskim kompanijama između 2004. i 2009. godine, a gdje se još jednom potvrdio fenomen zaokruživanja neto dobiti, ali i to da su manipulacije bile učestalije u prvim kvartalima u odnosu na zadnje te da postoje razlike u obrascima kozmetičkih manipulacija između pojedinih regija EU. Nastavno na provedeno istraživanje, u ovom radu provodi se zasebna analiza i usporedba financijskog rezultata (posebno za dobit, posebno za gubitak) za 10 europskih zemalja uključujući i Hrvatsku pomoću Benfordove zakonitosti za razdoblje od 2005. do 2014. godine.

## 1.2. Predmet istraživanja

Nastavno na utvrđeni problem istraživanja proizlazi predmet istraživanja. Predmet istraživanja, u teorijskom smislu, odnosi se na agencijski problem i problem asimetrije informacija. Poduzeća organizirana kao dionička društva funkcioniraju kao koalicija različitih interesnih skupina čiji kratkoročni ciljevi mogu biti konfliktni, što može dovesti do zlouporabe fleksibilnosti u računovodstvenom sustavu izvještavanja i prezentaciji financijskog rezultata kako bi se ispunili kratkoročni ciljevi jedne od konfliktnih (interesnih) skupina. Tako računovodstvene metode kojima se kratkoročno procjenjuje ili podcjenjuje imovina ili obveze mogu kratkoročno ispuniti ciljeve jedne od konfliktnih skupina. Brojni su razlozi za manipulacije s financijskim izvještajima među kojima su najčešći sljedeći (Sutton, 2000:678, prema Gulin):

- Smanjenje fiskalnih i regulatornih opterećenja,
- Težnja za što jeftinijim povećanjem kapitala,
- Izbjegavanje kršenja ugovora s vjerovnicima,
- Povećanje bogatstva menadžmenta.

Budući da je često između ilegalnih i legalnih računovodstvenih manipulacija vrlo tanka linija razgraničenja, potrebno je obratiti značajnu pozornost i na one manipulacije financijskim rezultatom koje ne dovode do direktnog kršenja zakonskih odredbi ili standarda financijskog izvještavanja ali one tijekom vremena nerijetko prerastu u obrasce prijevarnog financijskog izvještavanja.

Posebna skupina takvih manipulacija financijskim rezultatom su tzv. kozmetičke računovodstvene manipulacije, čiji su obrasci i učestalost predmet istraživanja ovog rada.

Kvaliteta financijskih izvještaja ne ovisi samo o regulativama, zakonima ili standardima već i o rezultatu ponašanja računovođa, menadžmenta i svih ostalih osoba uključenih u proces financijskog izvještavanja. Stoga je predmet empirijskog istraživanja ovog rada primjena Benfordove zakonitosti s ciljem otkrivanja tzv. kozmetičkih računovodstvenih manipulacija u iznosima prezentiranog financijskog rezultata (dobiti i gubitka) za razdoblje od 2005. do 2014. godine na uzorku izabranih zemalja iz Europske unije.

### 1.3. Istraživačke hipoteze i ciljevi istraživanja

Na temelju opisanog problema i predmeta istraživanja mogu se postaviti sljedeće radne hipoteze:

**H1: Pojava znamenki na drugom mjestu brojevnice pozicije će potvrditi očekivanu distribuciju od više nula (devetki) i manje devetki (nula) kod pozitivnih (negativnih) iznosa neto financijskog rezultata, što ukazuje na manipulativni proces zaokruživanja.**

Ovom hipotezom se pretpostavlja da

vjerojatnost pojedinih znamenki na određenim brojevnim pozicijama neće potvrditi očekivanu Benfordovu distribuciju te će to biti dokaz da se manipulira iznosima neto financijskog rezultata. Ovakve vrste manipulacija zovu se kozmetičke računovodstvene manipulacije, a podrazumijevaju psihološki fenomen zaokruživanja iznosa. Ovaj fenomen mogao bi se usporediti s cijenama proizvoda u trgovinama koje završavaju na 99 gdje trgovci žele zavarati kupca o visini cijene. S obzirom na to da čitamo s lijeva na desno cijena od npr. 9,99kn nam se čini puno manja nego cijena od 10,00kn. Tako i menadžeri u poduzećima upravljaju s iznosima neto dobiti na način da nisku zaradu prilagode kada su brojevi takvi da su taman ispod/iznad ključnih kognitivnih referentnih točaka.

**H2: Postoji značajna razlika u obrascima i učestalosti kozmetičkih računovodstvenih manipulacija između razvijenih i manje razvijenih tržišta kapitala u zemljama Europske unije.**

Ovom hipotezom se pretpostavlja da

učestalost i obrasci kozmetičkih računovodstvenih manipulacija ovise o razvijenosti tržišta kapitala u pojedinoj zemlji te o institucionalnim karakteristikama pojedinih zemalja. Razvijenija tržišta kapitala imaju i razvijenije institucionalne faktore kao što su zaštita dioničara, stroži nadzor nad primjenom općeprihvaćenih računovodstvenih načela standarda, efikasniji porezni sustav, veću kvalitetu revizije, viši stupanj edukacije i, općenito, kvalitetniji sustav korporativnog upravljanja zbog čega se očekuje da će na takvim tržištima biti manji stupanj korištenja kozmetičkih računovodstvenih manipulacija nego na onim manje razvijenim.

Svrha i cilj ovog rada je istražiti proces financijskog izvještavanja s aspekta učestalosti i obrazaca pojavljivanja tzv. kozmetičkih računovodstvenih manipulacija primjenom Benfordova zakona. Pritom će se poseban osvrt dati na analizu kozmetičkih računovodstvenih manipulacija na tržištu kapitala u Hrvatskoj te će se dobiveni rezultati usporediti s ostalim zemljama članicama Europske unije. Dodatno, analizirat će se postoje li razlike u korištenju i načinu korištenja kozmetičkih računovodstvenih manipulacija između razvijenih i manje razvijenih tržišta kapitala u zemljama Europske unije.

#### **1.4. Metode istraživanja**

Teorijski dio rada se temelji na pregledavanju stručne i znanstvene literature. Ta literatura predstavlja sekundarne podatke odnosno već postojeće podatke iz različitih izvora. U okviru izrade teorijskog dijela rada korištene su slijedeće metode znanstveno-istraživačkog rada, prilagođene prema teorijskom okviru:

- **Induktivna metoda** koja uključuje zaključivanje iz općih postavki do određenih pojedinačnih zaključaka te zaključivanje o općim sudovima na temelju pojedinačnih ili posebnih činjenica,
- **Deduktivna metoda** koja uključuje zaključivanje o općim sudovima na temelju pojedinačnih ili posebnih činjenica,
- **Metoda analize** koja uključuje rastavljanje složenih sudova, pojmova i zaključaka na jednostavnije sastavne dijelove te posebno izučavanje svakog dijela za sebe,
- **Metoda sinteze** koja predstavlja postupak spajanja elemenata ili dijelova u cjelinu, odnosno sastavljanje jednostavnih dijelova u sve složenije,
- **Metoda klasifikacije** predstavlja sistematsku i potpunu podjelu općeg pojma na posebne koje taj pojam obuhvaća,
- **Metoda deskripcije** predstavlja jednostavan opis činjenica te empirijsko potvrđivanje njihovih odnosa i veza,
- **Komparativna metoda** predstavlja metodu kojom se uočava i uspoređuje sličnost i zajednička obilježja dvaju ili više objekata, događaja ili pojava (uspoređivat će se hrvatske listane kompanije i europske).

U empirijskom dijelu korištene su prikladne statističke metode za testiranje postavljenih istraživačkih hipoteza.



## **1.5. Doprinos istraživanja**

Doprinos rada očituje se u znanstvenom ali i u praktičnom aspektu. Najveći doprinos rada je u utvrđivanju učestalosti i načina primjene kozmetičkih računovodstvenih manipulacija na uzorku od 10 europskih zemalja uključujući i Hrvatsku. Fer prezentacija financijskog rezultata poslovanja može biti narušena zbog motivacije menadžmenta za manipuliranjem financijskim izvještajima, stoga će se u ovom radu ukazati na uzroke pojavljivanja računovodstvenih manipulacija, njihove posljedice na donošenje odluka korisnika financijskih izvještaja, kozmetičke računovodstvene manipulacije i mogućnost primjene Benfordovog zakona u otkrivanju istih. Institucionalni okvir pojedinih zemalja predstavlja jedan od ključnih faktora kod pojavljivanja kozmetičkih računovodstvenih manipulacija, pa je očekivani doprinos ovog istraživanja i u usporedbi pojave kozmetičkih računovodstvenih manipulacija s obzirom na stupanj razvijenosti tržišta kapitala između analiziranih zemalja.

## **1.6. Struktura diplomskog rada**

Ovaj rad je strukturiran na način da uz uvod i zaključak sadrži šest poglavlja.

U uvodnom dijelu opisan je problem i predmet istraživanja, postavljene su hipoteze i ciljevi istraživanja, određene su metode koje se koriste u istraživanju te je prezentirana struktura i sadržaj rada

U drugom dijelu rada detaljno su objašnjeni temeljni financijski izvještaji, njihova kvalitativna obilježja i ciljevi izvještavanja, vrste temeljnih financijskih izvještaja i glavni korisnici financijskih izvještaja.

Treći dio rada pobliže objašnjava problematiku istraživanja, odnosno objašnjava što su računovodstvene manipulacije, koji su motivi za njihovo provođenje, koje vrste manipulacija postoje i koje su glavne tehnike računovodstvenog manipuliranja. Također objašnjeni su koncepti prijevare i pogreške u financijskim izvještajima, jer prijevare nerijetko nastaju kao posljedica manipuliranja financijskim izvještajima. U kontekstu računovodstvenih manipulacija, posebno je analiziran fenomen kozmetičkih računovodstvenih manipulacija.

U četvrtom poglavlju objašnjena je jedna od važnijih tehnika u otkrivanju kozmetičkih računovodstvenih manipulacija, Benfordov zakon. Uz pojmovno objašnjenje istraženo je kako

je otkriven ovaj zakon, mogućnost njegove primjene i ograničenja, matematički izvod te su dani primjeri pomoću kojih je objašnjena suština Benfordovog zakona.

Peto poglavlje odnosi se na empirijski dio istraživanja, odnosno definiran je uzorak od 10 europskih zemalja uključujući i Hrvatsku na kojem je provedeno istraživanje uz primjenu Benfordove zakonitosti te su na osnovi te zakonitosti donešeni i obrazloženi rezultati istraživanja.

U šestom poglavlju su iznesena zaključna razmatranja o provedenom istraživanju te spoznaje i činjenice do kojih se došlo istraživanjem i analizom.

## **2. SUSTAV FINANCIJSKOG IZVJEŠTAVANJA**

### **2.1. Temeljni financijski izvještaji**

Financijski izvještaji odražavaju sliku poslovanja poduzeća te stoga predstavljaju glavni izvor informacija za vanjske i unutarnje korisnike. Oni moraju pružiti istinit, fer, pouzdan i nepristran pregled imovine, obveza, kapitala, promjene financijskog položaja i dobiti ili gubitka. Od posebne su važnosti za vanjske korisnike jer oni nemaju direktan pristup internim računovodstvenim evidencijama.

U temeljnim odredbama Zakona o računovodstvu (NN 15/78, čl. 7) ističe se da je svaki poduzetnik dužan prikupljati i sastavljati knjigovodstvene isprave, voditi poslovne knjige, te sastavljati financijske izvještaje sukladno ovom Zakonu i na temelju njega donesenim propisima, poštujući pri tome standarde financijskog izvještavanja te temeljna načela urednog knjigovodstva.

Financijski izvještaji velikih poduzeća po Zakonu moraju biti revidirani od strane neovisnog revizora koji jamči da su informacije iz izvještaja prikazane u skladu s važećim računovodstvenim principima i s razumnom objektivnošću. Revizori, a osobito dioničari ovdje moraju biti posebno oprezni jer menadžeri nerijetko pribjegavaju različitim metodama manipuliranja financijskim izvještajima kako bi što optimističnije prikazali stanje poduzeća, o čemu će biti detaljnije raspravljeno u ovom radu.

U situacijama kada nastanu određene statusne promjene kao što su spajanje i pripajanje moraju se izraditi konsolidirani financijski izvještaji koje provode poduzetnici, pravne osobe koji su matica u odnosu prema podružnicama. Konsolidacija financijskih izvještaja se provodi radi utvrđivanja imovine, obveza, kapitala, prihoda, rashoda i financijskog rezultata svih članova konsolidirane grupe. Također financijski izvještaji moraju se izraditi i u situacijama kada dođe do stečaja i likvidacije.

Prema MSFI – om okvira za sastavljanje financijskih izvještaja objavljenom u narodnim novinama (2006) temeljne računovodstvene pretpostavke za sastavljanje računovodstvenih financijskih izvještaja su:

- Nastanak događaja,
- Neograničenost vremena poslovanja.

Sukladno Zakonu o računovodstvu (NN, 15/78, čl. 20) obvezi revizije godišnjih financijskih izvještaja podliježu:

- (1) Godišnji odvojeni i konsolidirani financijski izvještaji subjekata od javnog interesa te velikih i srednjih poduzetnika koji nisu subjekti od javnog interesa.
- (2) Poduzetnici koji su matična društva velikih i srednjih grupa ako nisu obveznici revizije sukladno stavku 1. ovoga članka.
- (3) Ako nisu obveznici revizije sukladno stavcima 1. i 2. ovoga članka, obvezi revizije podliježu i odvojeni i konsolidirani godišnji financijski izvještaji dioničkih društava te komanditnih društava i društava s ograničenom odgovornošću čiji odvojeni, odnosno konsolidirani podaci u godini koja prethodi reviziji prelaze pokazatelje u dva od sljedeća tri uvjeta:
  - iznos ukupne aktive 15.000.000,00 kuna
  - iznos prihoda 30.000.000,00 kuna
  - prosječan broj radnika tijekom poslovne godine – 25.
- (4) Ako nisu obveznici revizije sukladno stavcima 1., 2. i 3. ovoga članka, obvezi revizije godišnjih financijskih izvještaja podliježu godišnji odvojeni i konsolidirani financijski izvještaji poduzetnika koji su podnijeli zahtjev za uvrštavanje svojih vrijednosnih papira na uređeno tržište.
- (5) Reviziji podliježu i godišnji financijski izvještaji poduzetnika koji su sudjelovali u poslovnim spajanjima, odnosno podjelama kao preuzimatelji ili novoosnovana društva, ako obvezi revizije ne podliježu prema stavcima 1., 2., 3. i 4. ovoga članka.

Prema Zakonu o računovodstvu (NN, 15/78, čl. 19) poduzetnik i pravne i fizičke osobe dužni su sastavljati godišnje financijske izvještaje u obliku, sadržaju i na način propisan ovim Zakonom i na temelju njega donesenim propisima, a godišnje financijske izvještaje čine:

- izvještaj o financijskom položaju (bilanca)
- račun dobiti i gubitka
- izvještaj o ostaloj sveobuhvatnoj dobiti
- izvještaj o novčanim tokovima
- izvještaj o promjenama kapitala
- bilješke uz financijske izvještaje

## **2.2. Cilj temeljnih financijskih izvještaja**

Cilj temeljnih financijskih izvještaja prema Međunarodnim računovodstvenim standardima (MRS) i Međunarodnim revizijskim standardima (MRevS) je da pruže korisnicima realne i objektivne informacije o djelotvornosti poslovanja poduzeća koje su jako bitne u donošenju poslovnih odluka od strane vanjskih korisnika kao što su: investitori, namještenici, dobavljači, kupci, zajmodavci, vlada i njene agencije te ostala javnost ali i unutarnjim korisnicima kako bi mogli donositi potrebne poslovne odluke u svrhu poboljšanja poslovanja.

No uz sve pozitivne strane financijska izvješća odnose se na prošla financijska stanja koja su posljedica nekih odluka iz prošlosti stoga ne mogu dati u potpunosti sve informacije važne za donošenje važnih ekonomskih odluka.

## **2.3. Kvalitativna obilježja financijskih izvještaja**

Kvalitativna obilježja financijskih izvještaja jako su bitna za samo razumijevanje istih od strane korisnika financijskih izvještaja. MSFI objavljen u narodnim novinama (2006) navodi 4 vrste kvalitativnih obilježja:

- Razumljivost,
- Važnost,
- Značajnost i
- Pouzdanost.

**Razumljivost** - osnovna kvaliteta informacije pružene u financijskim izvještajima jest da je odmah razumljiva korisnicima. U tu se svrhu pretpostavlja da korisnici posjeduju dovoljno znanja o poslovnim i ekonomskim aktivnostima i o računovodstvu, te da imaju volju proučavati informacije s razboritom pažnjom. Informacije o složenim stvarima trebaju također biti uključene u financijske izvještaje zbog njihove važnosti korisnicima pri donošenju ekonomskih odluka i ne smiju se izostaviti samo stoga što bi mogle biti teško shvatljive određenim korisnicima.

**Važnost** - Da bi bila korisna, informacija mora biti važna za potrebe korisnika pri donošenju odluka. Informacija posjeduje kvalitetu važnosti kad utječe na ekonomske odluke korisnika pomažući im da procijene prošle, sadašnje ili buduće događaje, ili pak potvrđujući ili ispravljajući njihove prošle ocjene.

**Značajnost** - Informacija je značajna ako njezino izostavljanje ili krivo prikazivanje može utjecati na ekonomske odluke korisnika donijete na temelju financijskih izvještaja. Značajnost

ovisi o veličini stavke ili pogreške prosuđenoj u određenim okolnostima njenog izostavljanja ili pogrešnog prikazivanja. Stoga značajnost više osigurava granicu ili prijelomnu točku, nego što je primarno kvalitativno obilježje koje mora imati informacija da bi bila korisna.

**Usporedivost** - Da bi bila korisna, informacija mora također biti pouzdana. Informacija ima kvalitetu pouzdanosti kad u njoj nema značajne pogreške i pristranosti i u koju se korisnici mogu pouzdati da vjerno prikazuje ono što predstavlja ili bi se moglo razložno očekivati da to predstavlja.

## **2.4. Godišnji financijski izvještaji**

### **2.4.1. Izvještaj o financijskom položaju (bilanca)**

Bilanca kao temeljni financijski izvještaj predstavlja sustavan pregled imovine, kapitala i obveza gospodarskog subjekta na određeni datum. S obzirom da se podatci iz bilance temelje isključivo na povijesnim troškovima a ne na tržišnim vrijednostima oni daju samo opću procjenu vrijednosti tvrtke.

Bilanca predstavlja sliku finacijskog stanja poduzeća zato što prikazuje kako se imovina poduzeća osigurava, a može se osigurati kapitalom kreditora (obveze) ili vlasničkim kapitalom (glavnica). Također bilanca se sastavlja kako bi pokazala vezu između sredstava i njihovih izvora.

Osnovni elementi bilance su: imovina (sredstva, resursi) odnosno aktiva bilance i kapital (glavnica) i obveze odnosno pasiva bilance.

Aktiva bilance sadrži: potraživanja za upisani a neuplaćeni kapital, dugotrajnu imovinu, kratkotrajnu imovinu i plaćene troškove budućeg razdoblja i obračunani prihodi.

- a) Potraživanja za upisani a neuplaćeni kapital predstavlja dionice ili udjele upisane od poduzeća na kredit, odnosno na potraživanja za kapital koji je upisan ali nije uplaćen.
- b) Dugotrajna imovina. Dugotrajna imovina je imovina koja se pretvara u novčani oblik u razdoblju dužem od jedne godine. Podskupine dugotrajne imovine čine nematerijalna imovina, materijalna imovina, financijska imovina i potraživanja.
- c) Kratkotrajna imovina. Za razliku od dugotrajne imovine za kratkotrajnu imovinu se očekuje da se pretvori u novčani oblik u razdoblju kraćem od jedne godine.

Kratkotrajna imovina se može dalje podijeliti na: novac, potraživanja, financijsku imovinu i zalihe.

- d) Plaćeni troškovi budućeg razdoblja i obračunani prihodi. Odnose se na unaprijed plaćene troškove kao što su najamnine, zakupnine, premije osiguranja itd.

Sva imovina s kojom poduzeće raspolaže ima svoje porijeklo, a u pasivi bilance prema Vidučić (2004) prikazani su ti izvori u obliku potraživanja prema imovini tvrtke i to:

1. Obveze, tj novac koji se duguje vjerovnicima, te
2. Vlasnički kapital (equity), dionička glavica, ili neto vrijednost tvrtke

Sredstva kojim poduzeće raspolaže razlikujemo i po roku dospijeca a dijelimo ih na kratkoročne izvore, dugoročne izvore i trajne izvore (glavnica ili kapital). Pasiva bilance sadrži kapital i rezerve, dugoročna rezerviranja za rizike i troškove, dugoročne obveze, kratkoročne obveze i odgođeno plaćanje obveza i prihod budućih razdoblja.

Kapital poduzeća označava razliku između ukupne imovine i ukupnih obveza poduzeća tj to je onaj dio sredstava koji pripada vlasnicima nakon podmirenja svih obveza. Na povećanje kapitala utječu dodatna ulaganja vlasnika i neraspoređeni dobiti, a na smanjenje raspodjela vlasnicima i gubici u poslovanju.

- a) Kapital i rezerve obuhvaća upisani kapital, premije na emitirane dionice, revalorizacijske rezerve, rezerve i zadržana dobit ili preneseni gubitak.
- b) Dugoročne obveze su sve one obveze koje dospjevaju na naplatu u roku dužem od godine dana
- c) Kratkoročne obveze su sve one obveze koje dospjevaju na naplatu u roku kraćem od godine dana
- d) Dugoročna rezerviranja za rizike i troškove su prema MRS-u 37 obveze neodređenog vremena ili iznosa
- e) Odgođeno plaćanje troškova i prihod budućih razdoblja obuhvaća sve troškove koji su obračunati a nisu fakturirani, unaprijed naplaćene prihode budućeg razdoblja, obračunati zavisni troškovi nabave i odgođeno priznavanje prihoda.

Prema Vujević (2005) u teoriji i praksi uobičajeno se razlikuju , s obzirom na formu, vrijeme i razloge sastavljanja, slijedeće vrste bilanci i to:

- Početna bilanca,
- Zaključna bilanca,
- Probna, pokusna ili knjigovodstvena bilanca,
- Bruto bilanca,
- Neto bilanca,
- Konsolidirana bilanca,
- Zbrojna bilanca,
- Bilanca spajanja ili fuzije,
- Bilanca razdvajanja ili diobena bilanca,
- Bilanca sanacije,
- Bilanca likvidacije, itd.

#### 2.4.2. Račun dobiti i gubitka

Račun dobiti i gubitka prikazuje prihode i rashode, a njihovu razliku kao dobitak ili gubitak ovisno o tome jesu li veći prihodi ili rashodi. Sukladno Zakonu o računovodstvu (ZOR-u) informacije koje treba objaviti u ovom financijskom izvještaju određuje točka 75. MRS-a 1, a to su:

- Prihodi,
- Rezultat poslovnih aktivnosti,
- Financijski troškovi,
- Udjeli u dobiti i gubicima u povezanim društvima i zajedničkim pothvatima obračunani metodom udjela,
- Porez na dobit,
- Dobit ili gubitak od poslovnih aktivnosti,
- Manjinske interese (u slučaju konsolidiranih izvještaja),
- Neto dobit ili gubitak razdoblja.

Kod pozitivnog financijskog rezultata vrijednost kapitala se povećava dok se u obrnutom slučaju smanjuje. Povećanje kapitala bilježi se na pasivnoj strani bilance i služi kao izvor povećanja imovine u aktivi dok se smanjenje kapitala bilježi na strani pasive do visine kapitala i na strani aktive za dio koji prelazi visinu kapitala.



Prihodi se u računu dobiti i gubitka dijele na poslovne, financijske i izvanredne prihode. Poslovni prihodi nastaju iz redovnog poslovanja odnosno prodajom proizvoda i usluga. Financijski prihodi nastaju ulaganjem slobodno raspoloživih sredstava u dionice, obveznice, davanje kredita, tečajne razlike itd.

Rashodi se u računu dobiti i gubitka također javljaju u obliku poslovnih, financijskih i izvanrednih. Poslovni rashodi sadrže sve rashode koji su povezani s poslovnih prihodima odnosno prodanim proizvodima i uslugama. Financijski rashodi rezultat su korištenja tuđih novčanih sredstava u obliku kamata i tečajnih razlika. Izvanredni rashodi kao što i samo ime kaže nastaju zbog nekih neočekivanih situacija kao što su štete, kazne, otuđenja imovine i sl.

Kad od prihoda odbijemo troškove za prodano, uključujući amortizaciju i leasing naknade, dobivamo bruto maržu ili bruto profitnu maržu. Odbijemo li od bruto marže opće, prodajne i administrativne troškove dobivamo dobit iz poslovanja, tj zarada prije poreza i kamata odnosno EBIT. Do dobitka prije oporezivanja odnosno EBT dolazi se odbijanjem troškova financiranja, te konačno do neto dobitka odbijanjem poreza na dobitak.

Iz svega ovoga možemo doći do zaključka da se dobit (gubitak) može iskazati kao:

- Dobit iz redovnog poslovanja,
- Dobit od financijskih aktivnosti,

Kod utvrđivanja prihoda i rashoda Vujević (2005) polazi od dva osnovna koncepta:

1. Prema fakturiranoj realizaciji utvrđivanjem obračunske osnove, što znači da se prihodi i rashodi razmatraju u trenutku njihova nastanka samim činom prodaje i ispostavom fakture kad proizvodi napuste skladište i
2. Naplaćenom realizacijom utvrđivanjem novčane osnove, kada se prihodi i rashodi razmatraju u trenutku naplate potraživanja novčanih iznosa realiziranih proizvoda ili usluga.

#### 2.4.3. Izvještaj o novčanom tijeku

Izvještaj o novčanom tijeku u novije vrijeme sve više dobiva na važnosti iz razloga što je koristan i vanjskim i unutarnjim korisnicima. Naime na osnovu njega korisnici mogu procijeniti sposobnost poduzeća da ostvari budući čisti novčani tijek i da ispuni sve svoje obveze prema dobavljačima i dioničarima. Izvještaj o novčanom tijeku nam daje informacije o izvorima i upotrebi gotovine tijekom izvještajnog razdoblja ali nam također pruža i dobru bazu za procjenu budućih gotovinskih tijekova i potreba za financiranjem.

Novčani tijek sadrži dvije osnovne faze odnosno gotovinske primitke i gotovinske izdatke. Pod novčane primitke spadaju sva naplaćena potraživanja iz prodaje, primici od ulaganja, primici od prodaje fiksne imovine, zajmovi, primici od prodaje vrijednosnih papira i ostali, dok pod novčane izdatke spadaju svi izdaci za dobavljače, izdaci za plaće i naknade, izdaci za kupnju fiksne imovine, izdaci za kamate i dividende, ulaganja kapitala i ostali.

Za razumijevanje novčanog tijeka bitno je znati razliku između prihoda i primitaka te rashoda i izdataka iz razloga što svaki novčani prihod ne mora biti i primitak kao ni što svaki rashod ne mora biti izdatak.

Izvještaj o novčanim tijekovima još se dodatno segmentira s aspekta stvaranja novca iz poslovnih aktivnosti, investicijskih i financijskih aktivnosti kako bi se dobio što kvalitetniji izvještaj o tijeku gotovine.

Poslovne aktivnosti odnose se na osnovne odnosno redovne aktivnosti poduzeća i kao takve imaju najznačajniji utjecaj na financijski rezultat poduzeća. Među primjere poslovnih aktivnosti možemo navesti:

- Primici od prodaje osnovnih proizvoda ili pruženih usluga,
- Primici od provizija, subvencija i raznih drugih naknada,
- Primici od osiguravajućih društava,
- Izdaci proizašli iz obveza prema dobavljačima,
- Izdaci za poreze i doprinose,
- Izdaci za plaće i naknade.

Investicijske aktivnosti odnose se na promjene koje su vezane za dugotrajnu imovinu i potraživanja sa rokom dospjeća dužim od godine dana kao što su:

- Primici od prodaje nekretnina, opreme, postrojenja itd.,
- Primici od povrata kredita,
- Primici od prodaje dionica i obveznica,
- Izdaci za nabavu nekretnina, oprema, postrojenja itd.,
- Izdaci na osnovu vraćenih kredita,
- Izdaci za kupovinu dionica i obveznica.

Financijske aktivnosti odnose se na financiranje poslovanja poduzeća, a među primjere takvih aktivnosti možemo navesti:

- Primici od dionica, obveznica i drugih vrijednosnih papira,
- Primici od primljenih kredita,
- Izdaci za otplatu kredita,
- Izdaci za otkup vlastitih dionica,
- Izdaci za dividende i kamate.

Kod sastavljanja izvještaja o novčanom tijeku postoje dvije metode koje se koriste:

- Direktna metoda,
- Indirektna metoda.

Direktna metoda kao jednostavnija metoda stavlja u odnos sve primitke i izdatke iz poslovnih, investicijskih i financijskih aktivnosti te na taj način utvrđuje neto primitke. Većina korisnika sastavlja ovaj izvještaj jer je jednostavniji za primjenu i omogućuje im lakše prognoze likvidnosti i solventnosti u redovitom poslovanju.

Indirektna metoda koristi podatke iz bilance i računa dobiti i gubitka. Glavna karakteristika ove metode je ta što se kod nje svi primici i izdaci moraju korigirati za sve učinke nenovčanih transakcija kao što su amortizacija, promjena zaliha i poslovnih potraživanja i obveza.

#### 2.4.4. Bilješke uz financijske izvještaje

Prema Vidučić (2004) bilješke uz financijska izvješća predstavljaju detaljniju dopunu i razradu podataka iz bilance, računa dobiti i gubitka i izvješća o novčanom tijeku. Bilješke trebaju pratiti razradu podataka u pojedinim izvješćima radi smislene prezentacije ključnih informacija tj. trebaju dati dodatne informacije koje se ne vide u temeljnim financijskim izvještajima, a isto tako trebaju pojasniti određene pozicije u temeljnim financijskim izvještajima. Bilješke se svode na dvije osnovne grupe bilješki: one koje objašnjavaju računovodstvene politike koje su primijenjene u izradi izvješća te ostale podatke koji su važni za razumijevanje izvješća.

Među ostale podatke koji bi se trebali iznijeti u bilješkama spadaju podatci o dugoročnim zajmovima, planove emisija dionica, uvjete leasinga i dr. Odluku o tome koje će informacije biti uključene u bilješke odlučuje direktor. Iz toga razloga informacije iz bilješki znaju biti dosta nerazumljive zbog straha od izlaganja previše informacija konkurenciji.

## **2.5. Korisnici financijskih izvješća**

Korisnici financijskih izvješća dijele se na vanjske i unutarnje.

Među vanjske korisnike (stakeholdere) financijskih izvještaja spadaju dioničari, vjerovnici, potencijalni investitori, financijski analitičari, brokeri, porezne vlasti, gospodarske komore i udruge poslodavaca, sindikalne organizacije, vladina tijela i tijela organa lokalne uprave. Oni imaju različite interese u odnosu na različite aspekte tvrtke. Naime dioničari su zainteresirani za kretanje cijena dionica, isplatu dividendi, dok su vjerovnici zainteresirani za mogućnost servisiranja obveza i vjerojatnost bankrota poduzeća. S druge strane zaposlenici, lokalna zajednica i vlada zainteresirani su za podatke o broju zaposlenih, poštivanju ekoloških standarda, standarda sigurnosti na radu te podmirivanju obveza i doprinosa.

Unutarnji korisnici (stockholderi) financijskih izvješća su uprava, nadzorni odbor i menadžment. Oni koriste financijske izvještaje kako bi objektivizirali svoje odluke i time poboljšali cjelokupno poslovanje poduzeća. Financijska izvješća za potrebe interne analize koristi se za prognozu budućih uvjeta, kao baza za pregovore s vjerovnicima i investitorima i kao instrument interne revizije i kontrole.

### **3. RAČUNOVODSTVENE MANIPULACIJE**

#### **3.1. Pojam i obilježja računovodstvenih manipulacija**

Računovodstvene manipulacije pojavljuju se u poslovnom svijetu kao rezultat proturječnosti u ekonomskoj etici. Prema Mead (2003, p. 282.) u ekonomskoj je organizaciji razmjena moguća kada se zaborave univerzalna načela mišljenja ili religije, i proračunata razmjena stvara poseban tip zajedništva: "ta dva procesa stvorit će širu zajednicu čak i onda kad osobe nemaju nikakvih ideala za njeno ozbiljenje".

Slična situacija događa se i u financijskom izvještavanju u slučaju kad je menadžment vođen oportunističkim motivima, te tako dolazimo do računovodstvenih manipulacija odnosno manipuliranja s financijskim izvještajima. U svom istraživanju Gulin (2009) navodi da su manipulacije s cijenama vrijednosnih papira na burzama izvor manipulacija i u financijskim izvještajima te da one produbljuju konfliktnost između interesa različitih ciljnih skupina kao što su konflikti između poslovnih subjekata i poreznih vlasti a posebno konflikti interesa između investitora (dioničari, kreditori), menadžmenta i zaposlenih.

Najveći problem kod sprječavanja računovodstvenih manipulacija leži u tome što je ih je jako teško otkriti jer većina računovodstvenih manipulacija ne krši direktno odredbe zakona već samo njegov duh. Iz tog razloga jako je bitno razumjeti uzroke, procese i osnovne vrste računovodstvenih manipulacija kako bi se pronašla optimalna rješenja a njihov nadzor i reguliranje.

Kod pojmovnog definiranja računovodstvenih manipulacija pojavljuje se problem terminološke različitosti, naime u stručnoj literaturi postoji mnoštvo definicija, izraza i termina koji su povezani tj opisuju računovodstvene manipulacije. Neke od termina koji se pojavljuju su: igra brojevima, kuhanje ili friziranje knjiga, računovodstvene smicalice, manipuliranje zaradama, ugladivanje trenda zarada, kreativno računovodstvo, agresivno računovodstvo, računovodstvene prijevare i sl.

Copeland u svom istraživanju dolazi do prve značajne definicije računovodstvenih manipulacija gdje zaključuje kako menadžeri koriste računovodstvene alternative s ciljem manipuliranja dobiti, a računovodstvene manipulacije definira kao određene mogućnosti povećanja ili smanjenja prezentirane neto dobiti prema volji, dok istovremeno pravi razliku između računovodstvenog manipuliranja koje obuhvaća postupke namjernog povećanja ili smanjenja dobiti i onoga koji je usmjeren na redukciju varijacija u prezentiranoj dobiti tijekom dužeg vremenskog razdoblja.

Klepo (2005) u svojem radu dolazi do zaključka da je kod definiranja računovodstvenih manipulacija bitno naglasiti da sve one imaju neke zajedničke osobine koje ih vežu. Naime, bez obzira o kojoj je vrsti manipulacija riječ, sve su one rezultat nastojanja menadžmenta da putem računovodstvenog instrumentarija utječe na percepciju rizika koju tržišni sudionici ili ugovorne stranke povezuju s poslovanjem poduzeća, a zajednička osobina ovih manipulacija je modifikacija računovodstvenih brojeva za određene svrhe koje se razlikuju između grupa.

Posljednja važna stvar kod definiranja računovodstvenih manipulacija je njihov opseg. Pod tim pojmom misli se dali računovodstvene manipulacije ostaju unutar zakonskih okvira ili iskaču iz njega odnosno postaju prijevare. Ovaj rad će bit isključivo fokusiran na one manipulacije koje ostaju unutar zakona no treba imati na umu da se često takve manipulacije svojom agresivnom primjenom razviju u računovodstvene prijevare.

### **3.2. Poticaji, motivi i ciljevi manipuliranja**

Kad se govori o manipuliranju financijskim izvještajima u većini slučajevima menadžeri se navode kao glavni inicijatori manipulativnog ponašanja. Razlog takvog ponašanja menadžmenta leži u određenim koristima i interesima koji mogu biti ostvareni isključivo manipulativnim ponašanjem u okviru računovodstvenih politika i financijskih izvještaja. Koristi i interesi koje menadžment ostvaruje na osnovu takvog ponašanja može biti materijalne i nematerijalne prirode. Materijalne koristi odnose se na povećanje materijalnog bogatstva dok one nematerijalne mogu biti povećanje ugleda, zadržavanje posla, samozadovoljstvo, napredovanje itd. Motivi manipulativnog ponašanja najbolje bi se mogli prikazati poznatim "trokutom prijevare".



**Slika 1: Trokut prijevare**

Izvor: [www.accountingweb.com/practice/practice-excellence/3-ways-accountants-can-use-big-data-to-fight-fraud](http://www.accountingweb.com/practice/practice-excellence/3-ways-accountants-can-use-big-data-to-fight-fraud) [20.07.2016.]

Klepo (2005) u svom radu dijeli osnovne vrste manipulativnih poticaja na one koji dolaze s tržišta kapitala, kao i one koji su povezani s ugovornim kontekstom.

**Poticaji koji dolaze s tržišta kapitala** su u većini slučajeva povezani s cijenama dionica jer u slučaju pada cijene dionica poduzeće se mora suočavati s značajnim povećanjem troškova financiranja. Najveći poticaji se događaju kod inicijalne javne ponude (IPO) iz razloga što još uvijek ne postoji formirana cijena dionica na tržištu ali poticaja također ne nedostaje ni kod naknadne ponude vrijednosnih papira (SEO) i u situacijama u kojima menadžeri ili vlasnici prodaju značajne udjele svojeg vlasništva investitorima.

**Poticaji koji su povezani s ugovornim kontekstom** odnose se na određene bonuse odnosno menadžerske kompenzacije, dužničke ugovore i političke troškove i poreze.

Prema Klepo (2005) menadžeri će računovodstvenim putem povećavati neto dobit samo u području između donje i gornje razine potrebne za ostvarivanje bonusa.

Što se tiče dužničkih ugovora, menadžment će imati veće potrebe i više motiva za manipulativne akcije u slučajevima kada poduzeće ima velike dužničke obveze i veći trošak posuđivanja jer je u takvim slučajevima veći rizik od dodatnih troškova. Do ovog zaključka

došla je Sweeney (1994) kada je provela opsežno istraživanje računovodstvenih manipulacija u kontekstu dužničkih ugovora.

Manipulativne akcije vezane uz političke troškove i poreze događaju se iz razloga što veća dobit donosi obvezu plaćanja većeg iznosa poreza stoga se u ovom slučaju menadžerski naponi odnose na prikazivanje računovodstvene dobiti manjom nego što to ona u stvari je.

### **3.3. Vrste računovodstvenih manipulacija**

Kao što je već navedeno u prijašnjim poglavljima menadžeri u slučajevima kada žele utjecati na percepciju korisnika mogu računovodstvene zarade namjernim postupcima povećavati, snižavati, uglađivati ili "potapati" ovisno o interesima koje imaju. Metode koje se najčešće koriste u takvim slučajevima su:

- Manipuliranje zaradama,
- Uglađivanje trenda zarada,
- Računovodstvo "velike kupke",
- Kreativno računovodstvo.

#### **3.3.1. Manipuliranje zaradama**

Manipuliranje zaradama u većini slučajeva odnosi se na račun dobiti i gubitka, a označava namjerno povećanje ili smanjenje računovodstvenih zarada ovisno o ciljevima menadžmenta.

Novije istraživanje koje su proveli Stojanović i Borowiecki (2015) je pokazalo da su manipulativna povećanja zarada češće od manipulativnog smanjenja zarada.

Prema rezultatima do kojih se došlo u istraživanju koje su proveli Nissimm et al. (2005) situacije u kojima obično dolazi do precjenjivanja zarada jesu:

- Razina zarada je tek neznatno iznad sljedećih referentnih mjera: nule, razine zarada iz prethodne godine, konsenzualnih prognoza analitičara;
- Poduzeće će vrlo vjerojatno u bliskoj budućnosti prikupljati dodatni kapital ili će se uključiti u važne aktivnosti poslovnih spajanja ili pripajanja;
- Razina nenovčanih obračunskih kategorija je relativno visoka;
- Mijenjanje računovodstvenih politika;
- Mijenjanje revizora, odvjetnika, menadžera ili direktora;



- Poduzeće je uključeno u značajne transakcije s povezanim strankama.

Dok do podcjenjivanja zarada dolazi u slijedećim situacijama:

- Zarade su znatno niže od očekivanih prvenstveno zbog jednokratnih neuobičajenih stavki;
- Zarade su znatno više od očekivanih, a poduzeće najvjerojatnije neće prikupljati dodatni kapital te se neće uključivati u aktivnosti poslovnih spajanja ili pripajanja (u ovom slučaju postoji velika vjerojatnost da će poduzeće iskoristiti dobro poslovanje tekuće godine te će se stvarati skrivene rezerve za budućnost);
- Promjene menadžera;
- Razina nenovčanih obračunskih kategorija je relativno niska;
- Poduzeće je u pregovorima s sindikatom ili je predmetom tržišnih ili uvoznih istraga.

### 3.3.2. Ugladivanje trenda zarada

Ugladivanje trenda zarada podrazumijeva smanjenje varijabilnosti financijskog rezultata odnosno smanjivanje zarada u periodima veće zarade i prebacivanje djela tih zarada u periode za koje se očekuje manji iznos zarada. Na taj način menadžeri žele modificirati percepciju rizičnosti poslovanja odnosno kod korisnika financijskih izvještaja privid stabilnijeg poslovanja.



**Slika 2: Ugladivanje trenda zarada**

Izvor: [www.standardlife.co.uk/c1/funds/with-profits-overview.page](http://www.standardlife.co.uk/c1/funds/with-profits-overview.page) [20.07.2016.]

Kad se govori o vrstama ugađivanja trenda zarada one se dijele na one koje nastaju iz prirodnog tijeka poslovanja i na one koje nastaju namjernim akcijama menadžmenta. Osim vrsta ugađivanja trenda, moguće je identificirati i različite dimenzije ugađivanja tj različite metode kojima se ugađivanje postiže. Tako primjerice imamo međuperiodične i klasifikacijske metode ugađivanja trenda zarada. Međuperiodičnim metodama utječe se na nastanak i/ili priznavanje događaja, primjerice isporuka dobara se može uključiti ili isključiti iz određenog vremenskog razdoblja. Klasifikacijskim metodama utječe se na klasifikaciju pojedinih stavki u računu dobiti i gubitka, primjerice prihode ili rashode se smješta u izvanredne umjesto u operativne aktivnosti.

### **3.4. Računovodstvo "velike kupke"**

Računovodstvo velike kupke je metoda odnosno vrsta računovodstvene manipulacije pomoću koje menadžment utječe na kvartalne padove u zaradama pomoću diskrecijskih obračunskih kategorija. Ova metoda izvodi se većinom na način da se u tekućem razdoblju prikazuju troškovi iz budućeg razdoblja kada se ti troškovi ne mogu prekriti računovodstvenim postupcima te nakon "velikog kupanja" povećati zarade u narednim razdobljima.

### **3.5. Kreativno računovodstvo**

Kreativno računovodstvo je pre općenit pojam da bi se mogao detaljno objasniti jer on podrazumijeva širok spektar manipulativnih aktivnosti s ciljem modifikacije računovodstvenih informacija odnosno "uljepšavanja izloga" (eng. Window Dressing, termin koji se često koristi uz termin kreativno računovodstvo). On se ne vezuje isključivo na račun dobiti i gubitka već u manipulativne akcije uključuje i ostale financijske izvještaje. Prema istraživanju koje su proveli Stoloway i Breton (2000) termin kreativno računovodstvo većinom uključuje manipuliranje zaradama (bez kakvog povezivanja trenda zarada) i fokusira se značajno na klasifikacijskim manipulacijama (povezanim ili s računom dobiti i gubitka ili s bilancom).

Najbolju definiciju kreativnog računovodstva dao je Griffiths (1986, p. 1) u kojoj kaže: "Svaka kompanija u zemlji manipulira svojim zaradama. Svaki set objavljenih računa temelji se na knjigama koje su blago prokuhane ili dobro ispečene. Brojevi koji se prezentiraju dva puta godišnje investicijskoj javnosti mijenjaju se kako bi se zaštitilo od krivice. To je najveći

trik još od Trojanskog konja...Zapravo, ovakve prijevare jesu stvar savršeno dobrog ukusa. Potpuno su legitimne. One su kreativno računovodstvo."

Valja još napomenuti da se u SAD-u preferira pojam "manipuliranje zaradama", dok se u Europi koristi termin "kreativno računovodstvo".

### **3.6. Kozmetičke računovodstvene manipulacije**

#### **3.6.1. Definiranje kozmetičkih računovodstvenih manipulacija**

Kozmetičke računovodstvene manipulacije poprimaju sve više svjetske razmjere, a temelje se na psihološkom fenomenu zaokruživanja brojeva prema gore ili prema dolje do najbliže referentne točke koji se može pripisati kratkoj ljudskoj memoriji.

Ovaj fenomen prvi je otkrio Carslaw (1988) na primjeru poduzeća iz Novog Zelanda, a on bi se najbolje mogao opisati ako ga usporedimo s trgovačkim cijenama koje završavaju na 99 kao npr. 3,99. Naime ljudska kratkoročna memorija je ograničena i iz tog razloga pamti samo bitne znamenke u ovakvim iznosima, odnosno od lijeva prema desno. Gore navedena cijena od 3,99 u kupčevoj svijesti izgleda bliže cijeni od 3 nego cijeni od 4 novčane jedinice.

Thomas (1989) je na primjeru poduzeća iz SAD otkrio isti fenomen ali i u slučaju negativnih iznosa, u tom slučaju zabilježen je manjak nula i višak devetki.

Ovaj fenomen nije ostao ignoriran ni od strane menadžmenta. Na primjer, ako poduzeće ima neto dobit od 3,97 milijuna kuna, uz korištenje kozmetičkih računovodstvenih manipulacija iznos će se korigirati na 4,01 milijuna kuna što predstavlja povećanje od 0,04 milijuna ili 1%. To nije neki veliki iznos ali iz perspektive korisnika financijskih izvještaja predstavlja puno veću dobit jer više ne predstavlja dobit od 3 i "nešto" nego dobit od 4 milijuna kuna. Ovakvi slučajevi manipulacija najčešće se pojavljuju u slučajevima kada druga znamenka iznosi devet. U ovom slučaju u iznosima neto dobiti postojat će višak nula i manjak devetki što se može otkriti upotrebom Benfordovog zakona o kojem će biti više riječi u slijedećem poglavlju.

Kod negativnih iznosa neto dobiti postoji obrnuti proces. Naime u ovom slučaju ako su se prakticirale kozmetičke računovodstvene manipulacije postojat će višak devetki i manjak nula. Postupak je isti samo obrnutog redoslijeda. Primjerice ako je neto dobit u minusu i iznosi -2,01 milijuna kuna, ona će se korigirati na iznos od -1,98 milijuna kuna što opet

predstavlja mali iznos smanjenja gubitka ali u očima korisnika finansijskih izvještaja predstavlja puno manji gubitak.

Osim utjecaja na percepciju korisnika finansijskih izvještaja kao motiv za kozmetičke računovodstvene manipulacije Thomas (1989) vidi različite uvjete iz ugovornog konteksta kao što su budžeti, bonusi, posudbe itd.. posebno u slučajevima kada se radi o okruglim brojevima.

### 3.6.2. Obilježja kozmetičkih računovodstvenih manipulacija

Kao jedno od glavnih obilježja kozmetičkih računovodstvenih manipulacija je to da se one kod pozitivnih iznosa pojavljuju najčešće ako je druga znamenka broj devet što je i logično s obzirom da se u tom slučaju ne radi o nekoj velikoj promjeni iznosa (većinom iznosi oko 1%). Kod negativnih iznosa situacija je obrnuta odnosno pojavljuje se ako je druga znamenka nula.

U svojim istraživanjima Stojanovic i Borowiecki (2015) koje su proveli na osnovu kvartalnih izvještaja otkrili su da se kozmetičke računovodstvene manipulacije najzastupljenije u prvom kvartalu dok je njihova prisutnost najmanje zastupljena u četvrtom kvartalu.

Kinnunen i Koskela (2001) u svojim istraživanjima na Europskim poduzećima otkrili su više obilježja kozmetičkih računovodstvenih manipulacija.

Prva od njih je da su kozmetičke računovodstvene manipulacije bile zastupljenije u Zapadnim i Nordijskim Europskim zemljama nego u Istočnim zemljama Europe kad se radilo o pozitivnim iznosima dok su negativni iznosi pokazali sistematičnije devijacije i u Zapadnoj i u Istočnoj Europi.

Drugo obilježje je da su u slabije kontroliranim računovodstvenim sustavima kozmetičke računovodstvene manipulacije bile puno manje značajnije na vrhu računa dobiti i gubitka nego na dnu. Također navode da su kozmetičke računovodstvene manipulacije manje izražene i manje značajne na iznosima neto prodaje nego neto dobiti.

Treće obilježje je da pojavljivanje kozmetičkih računovodstvenih manipulacija ovisi o više institucionalnih faktora. Primjerice u uvjetima visoke zaštićenosti dioničara, visokog troška revizije, dobrog poklapanja finansijskog i poreznog računovodstvenog sustava i visokog nivoa obrazovanja i ekonomske razvijenosti zemlje postoji manja mogućnost za kozmetičke računovodstvene manipulacije. S druge strane, kad postoji određena sloboda u izvještavanju

odnosno računovodstvenim standardima, kad je u društvima veći jaz između uspješnih i manje uspješnih pojedinaca i kad postoji veća želja za uspjehom, odnosno kad su ciljevi postavljeni visoko postoji i veća vjerojatnost da će doći do kozmetičkih računovodstvenih manipulacija.

### 3.6.3. Pregled istraživanja vezanih za kozmetičke računovodstvene manipulacije

Prvi koji je koristio Benfordov zakon kako bi otkrio nepravilnosti u distribuciji neto dobiti bio je škotski matematičar Scott Carslaw 1988. godine. On je utvrdio višak nula i nedostatak devetki na drugom mjestu kod pozitivnih iznosa neto dobiti na primjeru jedne kompanije iz Novog Zelanda.

Kao i Carslaw, Thomas (1989) je koristio Benfordov zakon također kako bi otkrio nepravilnosti u distribuciji neto dobiti samo što je on otkrio i obrnuti uzorak, tj. višak devetki i nedostatak nula kod negativnih iznosa neto dobiti.

Kinnunen i Koskela (2001), su proveli istraživanje na svjetskoj razini u periodu od 1995. – 1999. na osnovu kojeg su došli do zaključka da su kozmetičke računovodstvene manipulacije bile zastupljenije na zadnjim pozicijama financijskih izvještaja te da njihova pojava ovisi o više različitih institucionalnih faktora.

Istraživanje na pozitivnim i negativnim kvartalnim izvješćima firmi iz SAD – a proveli su Guan L. et. al. (2006) u kojem su ispitali utjecaj revizije na financijsko izvještavanje. Pokazalo se da firme koriste kozmetičke računovodstvene manipulacije u svim kvartalima ali najmanje u četvrtom jer je to jedini revidirani kvartal što pokazuje bitnu ulogu revizije u sprječavanju kozmetičkih računovodstvenih manipulacija.

Utjecaj uvođenja Sarbanes – Oxley zakona 2002. godine na financijsko izvještavanje Američkih firmi proveli su Guan L. i June J. (2008). Istraživanje se provelo za razdoblje od dvije godine prije i poslije uvođenja SOX – a. Istraživanje je pokazalo kako je pojava kozmetičkih računovodstvenih manipulacija signifikantno smanjena nakon uvođenja SOX – a što znači da je SOX doprinijeo do smanjenja manipulativnog ponašanja od strane Američkih firmi.

Niskanen J. i Keloharju M. (2010.) istražili su pojavljuju li se kozmetičke računovodstvene manipulacije u financijskim izvještajima Finskih poduzeća. Istraživanje je pokazalo slične rezultate kao i s Američkim i Novozelandskim firmama. Menadžeri Finskih tvrki također su

participirali u korištenju kozmetičkih računovodstvenih manipulacija većinom u želji da smanje svoje porezne obveze. Ono što se pokazalo neočekivano je da je u izvještajima bio manjak devetki i osmica uz statističko signifikantno više sedmica i šestica.

Thomas E. i Wilson J. (2012.) su proveli istraživanje na firmama iz SAD – a na temelju podatka iz 2009. godine u kojem se pokazalo da nije bilo zabilježeno korištenje kozmetičkih računovodstvenih manipulacija zahvaljujući uvođenju SOX – a.

Zanimljivo istraživanje na primjeru kompanija iz SAD – a i Tajvana u periodu od 1990. – 2011. koje su proveli Fengyi L. i Sheng – Fu W. (2014.) dovelo je do zaključka da se kozmetičke računovodstvene manipulacije pojavljuju i u razvijenim tržištima i u onima u razvoju s tim da su u tržištima u razvoju menadžeri imali više poticaja za korištenje kozmetičkih računovodstvenih manipulacija. Također pokazalo se da u razvijenim tržištima postoje i ravijenije tržišne regulacije te da su se one pokazale kao učinkovita mjera u suzbijanju takvih i sličnih manipulacija s financijskim izvještajima.

Kao jedino istraživanje u okviru bilančnih pozicija proveli su Gayer D. i Drachsler C. (2014.) koji su testirali pojavljuju li se kozmetičke računovodstvene manipulacije na pozicijama dugoročnih obveza. Istraživanje je potvrdilo očekivanja odnosno kozmetičke računovodstvene manipulacije bile se zastupljene čak i u bilanci.

Aktualnost ovakvih istraživanja potvrđuje i nedavno objavljeno istraživanje koje su proveli Stojanović i Borowiecki (2015) na listanim Europskim kompanijama između 2004. i 2009. godine, a gdje se još jednom potvrdio fenomen zaokruživanja neto dobiti ali i to da su manipulacije bile učestalije u prvim kvartalima u odnosu na zadnje te da postoje razlike u obrascima kozmetičkih manipulacija između pojedinih regija EU.

### **3.7. Prijevare i pogreške u financijskim izvještajima**

Soltani (2010, p. 533) definira pogreške kao nenamjeran pogrešan prikaz u financijskim izvještajima uključujući izostavljanje iznosa ili objavljene informacije kao primjerice:

- Pogreška u prikupljanju ili obradi koji se koriste u sastavljanju fiancijskih izvještaja,
- Neutemeljena računovodstvena procjena nastala zbog propusta ili pogrešnog prikazivanja činjenica,

- Pogreška u primjeni računovodstvenih načela koje se odnose na iznos, mjerenje, priznavanje, klasificiranje, način prezentiranja ili objavljivanja.

Također Soltani (2010, p. 534) definira prijevarno financijsko izvještavanje kao namjerno pogrešno prikazivanje uključujući izostavljanje iznosa ili objavljenih informacija u financijskim izvještajima koji su pripremljeni na način da obmane korisnike financijskih izvještaja, a učinak toga je da financijski izvještaji nisu prezentirani u svim značajnim odrednicama sukladno opće prihvaćenim računovodstvenim načelima. "Prijevarno financijsko izvještavanje može uključivati sljedeće":

- Manipuliranje, falsificiranje (uključujući krivotvorenje) ili promjenu računovodstvenih zapisa i popratne dokumentacije na temelju kojih su pripremljeni financijski izvještaji,
- Pogrešno prikazivanje ili namjerno ispuštanje događaja, transakcija ili drugih značajnih informacija u financijskim izvještajima,
- Namjerna pogrešna upotreba računovodstvenih načela koja se tiču iznosa, klasificiranja te način prezentiranja ili objavljivanja.

## 4. BENFORDOV ZAKON

Ovaj zakon počiva na činjenici da se određene znamenke u skupovima pojavljuju češće od ostalih. Prema Benfordovom zakonu u skupu brojeva s bazom 10 broj 1 ima najveću vjerojatnost pojavljivanja, odnosno 30,1%, nakon njega slijedi broj 2 s vjerojatnošću od 17,6%, odnosno što je broj veći manja je vjerojatnost njegova pojavljivanja. Tako primjerice broj 9 ima najmanju vjerojatnost pojavljivanja u skupu.

### 4.1. Otkriće Benfordovog zakona

Još u vrijeme dok nisu postojala ni džepna računala i dok se sve računalo pomoću papira i olovke, a složene matematičke operacije obavljale su se pomoću nepreglednih stranica logaritamskih tablica, američki astronom i matematičar Simon Newcomb 1881. godine primjetio je kako su stranice logaritamskih tablica koje počinju s 1 puno istrošenije i upotrebljivnije od ostalih. Nakon što je to primjetio, Newcomb je odlučio analizirati skupine podataka koje se pojavljuju u prirodi te je došao do teze koju danas zovemo Benfordovim zakonom. U to vrijeme, njegovo otkriće je ostalo ignorirano i iz tog razloga ne nosi naziv po njemu.

Tek 1938. fizičar Frank Benford uočio je istu pojavu kao i Newcomb samo što se on koristio puno većom bazom podataka, odnosno 20229 skupina različitih podataka. Naime Benford je proučavao skupine podataka iz mnoštva različitih izvora kao što su npr: brojnost populacija, duljine rijeka, površine jezera, brojeve iz telefonskog imenika, sportska statistika, atomska težina itd.

|      |                    | Prva znamenka |      |      |      |      |     |     |     |      |        |
|------|--------------------|---------------|------|------|------|------|-----|-----|-----|------|--------|
| Stu. | Naziv              | 1             | 2    | 3    | 4    | 5    | 6   | 7   | 8   | 9    | Uzorak |
| A    | Rijeke, površina   | 31.0          | 16.4 | 10.7 | 11.3 | 7.2  | 8.6 | 5.5 | 4.2 | 5.1  | 335    |
| B    | Stanovništvo       | 33.9          | 20.4 | 14.2 | 8.1  | 7.2  | 6.2 | 4.1 | 3.7 | 2.2  | 3259   |
| C    | Konstante          | 41.3          | 14.4 | 4.8  | 8.6  | 10.6 | 5.8 | 1.0 | 2.9 | 10.6 | 104    |
| D    | Novine             | 30.0          | 18.0 | 12.0 | 10.0 | 8.0  | 6.0 | 6.0 | 5.0 | 5.0  | 100    |
| E    | Specifična toplina | 24.0          | 18.4 | 16.2 | 14.6 | 10.6 | 4.1 | 3.2 | 4.8 | 4.1  | 1389   |
| F    | Tlak               | 29.6          | 18.3 | 12.8 | 9.8  | 8.3  | 6.4 | 5.7 | 4.4 | 4.7  | 703    |
| G    | H. P. gubitak      | 30.0          | 18.4 | 11.9 | 10.8 | 8.1  | 7.0 | 5.1 | 5.1 | 3.6  | 690    |
| H    | Molekularna težina | 26.7          | 25.2 | 15.4 | 10.8 | 6.7  | 5.1 | 4.1 | 2.8 | 3.2  | 1800   |



|   |                                   |           |           |           |           |           |           |           |           |     |      |
|---|-----------------------------------|-----------|-----------|-----------|-----------|-----------|-----------|-----------|-----------|-----|------|
| I | Isušivanje                        | 27.1      | 23.9      | 13.8      | 12.6      | 8.2       | 5.0       | 5.0       | 2.5       | 1.9 | 159  |
| J | Atomska težina                    | 47.2      | 18.7      | 5.5       | 4.4       | 6.6       | 4.4       | 3.3       | 4.4       | 5.5 | 91   |
| K | $n^{-1}$ , $\sqrt[n]{n}$          | 25.7      | 20.3      | 9.7       | 6.8       | 6.6       | 6.8       | 7.2       | 8.0       | 8.9 | 5000 |
| L | Dizajn                            | 26.8      | 14.8      | 14.3      | 7.5       | 8.3       | 8.4       | 7.0       | 7.3       | 5.6 | 560  |
| M | <i>Reader's Digest</i>            | 33.4      | 18.5      | 12.4      | 7.5       | 7.1       | 6.5       | 5.5       | 4.9       | 4.2 | 308  |
| N | Cijene                            | 32.4      | 18.8      | 10.1      | 10.1      | 9.8       | 5.5       | 4.7       | 5.5       | 3.1 | 741  |
| O | Rendgenska voltaža                | 27.9      | 17.5      | 14.4      | 9.0       | 8.1       | 7.4       | 5.1       | 5.8       | 4.8 | 707  |
| P | Statistika baseballu <sup>u</sup> | 32.7      | 17.6      | 12.6      | 9.8       | 7.4       | 6.4       | 4.9       | 5.6       | 3.0 | 1458 |
| Q | Vodljivost                        | 31.0      | 17.3      | 14.1      | 8.7       | 6.6       | 7.0       | 5.2       | 4.7       | 5.4 | 1165 |
| R | Adrese                            | 28.9      | 19.2      | 12.6      | 8.8       | 8.5       | 6.4       | 5.6       | 5.0       | 5.0 | 342  |
| S | $n^1, n^2, \dots, n!$             | 25.3      | 16.0      | 12.0      | 10.0      | 8.5       | 8.8       | 6.8       | 7.1       | 5.5 | 900  |
| T | Stopa smrtnosti                   | 27.0      | 18.6      | 15.7      | 9.4       | 6.7       | 6.5       | 7.2       | 4.8       | 4.1 | 418  |
|   | Prosjek                           | 30.6      | 18.5      | 12.4      | 9.4       | 8.0       | 6.4       | 5.1       | 4.9       | 4.7 | 1011 |
|   | Vjerojatna pogreška               | $\pm 0.8$ | $\pm 0.4$ | $\pm 0.4$ | $\pm 0.3$ | $\pm 0.2$ | $\pm 0.2$ | $\pm 0.2$ | $\pm 0.3$ |     |      |

### Slika 3: Relativne frekvencije prvih znamenaka u različitim skupinama podataka

Izvor: [e.math.hr/benford/index.html](http://e.math.hr/benford/index.html) [20.07.2016.]

U svim tim skupinama podataka Benford je primjetio da se znamenka 1 pojavljuje najčešće, pa znamenka 2 itd. No za razliku od Newcamba Benfordov rad bio je primjećen te je po njemu ova zanimljiva činjenica u svijetu brojeva nazvana "**Benfordovim zakonom**" ali za široku primjenu ovog zakona ipak se moralo pričekati do razvoja računalne tehnologije i programskih alata koji su njegovu primjenu omogućili jednostavnijom i dostupnijom.

## 4.2. Koncept Benfordovog zakona

Koncept Benfordovog zakona temelji se na vjerojatnosti pojavljivanja određenog broja u skupu različitih brojeva. Prema Benfordovom zakonu nema svaki broj istu vjerojatnost pojavljivanja, odnosno broj jedan ima najveću vjerojatnost dok broj devet ima najmanju.

Ova pojava najbolje bi se mogli objasniti na primjeru rasta stanovništva u nekom gradu. Primjerice, ako grad od 10 000 stanovnika raste godišnje za 2%. Za 36 godina broj stanovnika doseći će 20 000 što znači da će 36 godina početna znamenka u broju stanovnika biti broj 1. Slijedeća promjena početne znamenke dogodit će se za 20 godina kada će grad imati 30 000 stanovnika odnosno 16 godina prije, tj broj 1 će biti početna znamenka 16 godina više od broja 2.

U *Tablici 1.* možemo vidjeti koliko će godina grad imati pojedinu znamenku kao početnu.

**Tablica 1: Frekvencije pojavljivanja prve znamenke u broju stanovnika**

|                  |    |    |    |    |   |   |   |   |   |
|------------------|----|----|----|----|---|---|---|---|---|
| Početna znamenka | 1  | 2  | 3  | 4  | 5 | 6 | 7 | 8 | 9 |
| Broj godina      | 36 | 20 | 15 | 11 | 9 | 8 | 7 | 5 | 6 |

Izvor: [e.math.hr/benford/index.html](http://e.math.hr/benford/index.html) [20.07.2016.]

Tablica nam pokazuje da se relativne frekvencije pojavljivanja znamenke 1 kao početne znamenke u broju stanovnika ponašaju u skladu s Benfordovim zakonom.

No Benfordov zakon ne vrijedni za sve skupine podataka, odnosno Benfordov zakon treba podatke koji nisu ni potpuno slučajni ili uniformno distribuirani kao što je to primjer s brojevima lutrije, a ni potpuno ograničeni kao što to mogu biti godine nekih poznatih ljudi, primjerice političara gdje prva znamenka definitivno neće biti 1, npr. 18 godina.

Matematička istraživanja dovela su do zaključka da što više podatci variraju, to se relativne frekvencije brojeva više približavaju relativnim frekvencijama iz Benfordovog zakona.

Benfordov zakon možemo prikazati i pomoću matematičke formule koju je postavio sam Benford:

$$P(D = d) = \log_{10}\left(1 + \frac{1}{d}\right)$$

$$d=1,2,\dots,9.$$

On je pretpostavio da udaljenost između broja i njegovog sljedbenika, podijeljena s cijelom dužinom skale, daje vjerojatnost da će broj biti prva znamenka u drugoj skupini podataka.


Vjerojatnost pojavljivanja prve znamenke u bazi brojeva vidljivo nam je iz rasporeda logaritamskih tablica. Iz tablice možemo vidjeti da je gotovo trećini brojeva prva znamenka broj jedan. U *Tablici 2.* prikazana je vjerojatnost pojave idućeg broja odnosno intervala pojavljivanja koji se svaki put sve više smanjuje tako da se broj 9 pojavljuje u najmanje slučajeva.

**Tablica 2: Logaritamska skala**

| Logaritamska skala |       |       |      |      |      |      |      |      |
|--------------------|-------|-------|------|------|------|------|------|------|
| 1                  | 2     | 3     | 4    | 5    | 6    | 7    | 8    | 9    |
| 30,1%              | 17,6% | 12,5% | 9,7% | 7,9% | 6,7% | 5,8% | 5,1% | 4,6% |

Izvor: e.math.hr/benford/index.html [20.07.2016.]

Ova zanimljiva pojava može se prikazati i pomoću histograma odnosno poligona raspodjele.



**Slika 1: Histogram**

Izvor: e.math.hr/benford/index.html [20.07.2016.]

#### 4.3. Prednosti i nedostaci Benfordovog zakona

Benfordov zakon nakon svog otkrivanja nije bio lako primjenjiv no s razvojem tehnologije odnosno informatike postao je snažan alat koji se može koristiti u različitim poljima kao što su matematika, fizika, ekonomija, bankarstvo, informatika, revizija i druge. Posebno je

zanimljiv u poljima ekonomije zbog otkrivanja računovodstvenih prijevара i lažiranja podataka kod plaćanja poreza. Zato je već u nekim državama postao standardan alat u otkrivanju utaja poreza. Jedno zanimljivo otkriće pomoću Benfordovog zakona bilo je otkrivanje lažnih makroekonomskih podataka Grčke koje je utjecalo na razvoj ekonomske krize u EU.

S druge strane, postoje i situacije u kojima Benfordov zakon nije primjenjiv. Prema Belak (2011) to se odnosi na situacije u kojima se radi o skupovima podataka s dodijeljenim brojevima, brojeve formirane s namjerom (psihološke cijene), račune s velikim količinama brojeva specifičnih jednoj tvrtki, brojeve koji su uvjetovani minimumom i maksimumom ili kada uopće nisu knjižene transakcije.

U zaključnom razmatranju valja nadodati kako bilo kakva odstupanja od Benfordove distribucije ne podrazumijevaju automatski i prijevaru, stoga sve podatke treba dodatno analizirati i razumno interpretirati. Tako primjerice u nekim situacijama kada postoje odstupanja ne znači automatski da je došlo do prijave niti je u situacijama kada nema odstupanja sigurno reći da nije došlo do prijave.

## **5. ISTRAŽIVANJE KOZMETIČKIH RAČUNOVODSTVENIH MANIPULACIJA U ZEMLJAMA EU PRIMJENOM BENFORDOVE ZAKONITOSTI**

### **5.1. Definiranje uzorka**

Uzorak za testiranje postavljenih hipoteza su iznosi neto financijskih rezultata poduzeća iz deset europskih zemalja među kojima su Njemačka, Francuska, Velika Britanija, Italija, Španjolska, Poljska, Bugarska, Hrvatska, Rumunjska i Švedska gledani kroz razdoblje od 2005. do 2014. godine, koji su prikupljeni iz revidiranih godišnjih financijskih izvještaja.

Poduzorak odnosi se na razvijene i manje razvijene zemlje iz glavnog uzorka. Kriterij određivanja razvijenosti su makroekonomski pokazatelji kao što su inflacija, rast BDP – a, nezaposlenost i bruto javni dug. Na temelju određenih kriterija odnosno podataka koje je objavila Europska komisija među razvijene zemlje spadaju Njemačka, Francuska, Velika Britanija, Poljska i Švedska dok među one manje razvijene spadaju Bugarska, Hrvatska, Italija, Španjolska i Rumunjska.

Prikupili smo uzorak od 65249 iznosa neto financijskih rezultata iz godišnjih izvještaja od kojih se 41287 iznosa odnosi na dobit dok se 23962 iznosa odnosi na gubitak.

## **5.2. Primijenjena metodologija**

Cilj rada je empirijski istražiti manipulira li se na europskom tržištu kapitala s računovodstvenim podacima, točnije s iznosima neto financijskog rezultata poduzeća.

Da bi započeli empirijsko istraživanje postavljena je sljedeća glavna hipoteza koja će se pokušati dokazati ili opovrgnuti:

- *Vjerojatnost pojave brojeva na određenim brojevnim pozicijama neće potvrditi očekivanu Benfordovu distribuciju i bit će dokaz da se manipulira iznosima neto financijskog rezultata.*

Zatim, vodeći se prethodnim istraživanjima definiramo i pomoćne hipoteze:

H1: Pojava znamenki na drugom mjestu brojevnice pozicije će potvrditi očekivanu distribuciju od više nula (devetki) i manje devetki (nula) kod pozitivnih (negativnih) iznosa neto financijskog rezultata, što ukazuje na manipulativni proces zaokruživanja.

H2: Postoji značajna razlika u obrascima i učestalosti kozmetičkih računovodstvenih manipulacija između razvijenih i manje razvijenih tržišta kapitala u zemljama Europske unije.

Da bi testirali prethodno navedene hipoteze koristili smo Benfordovu zakonitost, Hi – kvadrat distribuciju i normalnu distribuciju, tj. z-test. Testiranje je obavljeno u Microsoft Office Excel-u.

Hi-kvadrat test se vrlo često koristi u statistici kako bi se zaključilo da li dva skupa podataka, na određenoj razini značajnosti, odgovaraju jedni drugima. U istraživanju se koristi za provjeru jesu li sve znamenke u cjelini u skladu s Benfordovim zakonom. Hi-kvadrat vjerojatnost je izračunata uz pomoć funkcije CHITEST (actual\_range;expected\_range).

Z-test se koristi kao mjera statističke značajnosti odstupanja od Benfordovog zakona za svaku kombinaciju brojki zasebno (Krokar, Žgela, 2009:39-51). Z-vrijednost je računata uz pomoć sljedeće formule (Mark Nigrini i Linda Mittermeier 1997):

$$z = \frac{|p_k - b_k|}{\sqrt{(b_k * (1 - b_k)/n)}} - \frac{1}{2n}$$

$p_k$  – stvarna proporcija ( $p_k = f_k/n$ ),  $b_k$  - benfordova proporcija, i  $n$  – ukupan uzorak.

Razinu signifikantnosti određujemo 5% ( $\alpha=5\%$ ), što znači da postoji samo 5% šanse da je razlika između stvarnih i očekivanih proporcija slučajna. Granična Z-vrijednost iznosi 1,96, dok visoke vrijednosti Hi-kvadrat vjerojatnosti kao npr. 93% pokazuju dobru podudarnost između stvarnih i očekivanih frekvencija, dok male vrijednosti kao npr. 3% ukazuju na loše podudaranje, tj. vrijednosti manje od 5% sugeriraju da postoji mala vjerojatnost da podatci odgovaraju Benfordovoj distribuciji.

### 5.3. Rezultati istraživanja

Zakon tvrdi, suprotno našim očekivanjima, da se u sustavu s bazom 10 najviše pojavljuje broj 1 te što je znamenka veća to se pojavljuje u sve manje slučajeva kao vodeća, da bi se znamenka 9 pojavljivala kao vodeća otprilike jednom u dvadeset slučajeva.

Očekivana pojava broja D1, kao prve znamenke, može se aproksimirati sljedećim izrazom:

$$\text{Prob} (D1 = d1) = \log_{10} (1 + (1/d1)) \\ d1 = 1,2,3...9.$$

Da bi testirali pomoćne hipoteze zanimaju nas brojevi na drugoj brojevnoj poziciji. Očekivana pojava broja D2, kao druge znamenke, može se aproksimirati sljedećim izrazom:

$$\text{Prob} (D_2 = d_2) = \sum_{d_1=1}^9 \log_{10}(1 + (1/d_1 d_2))$$

Sljedeća slika prikazuje vjerojatnosti pojavljivanja brojeva na prvih pet brojevnih pozicija:

| Digit | 1 <sup>st</sup> | 2 <sup>nd</sup> | 3 <sup>rd</sup> | 4 <sup>th</sup> | 5 <sup>th</sup> or higher |
|-------|-----------------|-----------------|-----------------|-----------------|---------------------------|
| 0     |                 | 11.97%          | 10.18%          | 10.02%          | 10.00%                    |
| 1     | 30.10%          | 11.39%          | 10.14%          | 10.01%          | 10.00%                    |
| 2     | 17.61%          | 10.88%          | 10.10%          | 10.01%          | 10.00%                    |
| 3     | 12.49%          | 10.43%          | 10.06%          | 10.01%          | 10.00%                    |
| 4     | 9.69%           | 10.03%          | 10.02%          | 10.00%          | 10.00%                    |
| 5     | 7.92%           | 9.67%           | 9.98%           | 10.00%          | 10.00%                    |
| 6     | 6.69%           | 9.34%           | 9.94%           | 9.99%           | 10.00%                    |
| 7     | 5.80%           | 9.04%           | 9.90%           | 9.99%           | 10.00%                    |
| 8     | 5.12%           | 8.76%           | 9.86%           | 9.99%           | 10.00%                    |
| 9     | 4.58%           | 8.50%           | 9.83%           | 9.98%           | 10.00%                    |

**Slika 5: Vjerojatnost pojavljivanja brojeva na prvih pet brojevnih pozicija**

Izvor: <http://investexcel.net/benfords-law-excel/> [20.07.2016]

Kao što je predloženo od strane Thomas (1989) uzorak od 65249 iznosa neto financijskih rezultata dijelimo na pozitivne i negativne brojeve te tako dobivamo dva poduzorka od 41287 iznosa neto dobiti i 23962 iznosa gubitka.


U *Tablici 3.* i na *Grafikonu 1.* prikazane su frekvencije i proporcije znamenki na prvoj brojevnoj poziciji u iznosima neto dobiti.

**Tablica 3: Frekvencije i proporcije znamenki na prvoj brojevnoj poziciji u iznosima neto dobiti**

| Znamenka     | Stvarne<br>Frekvencije<br>f(k) | Očekivane<br>frekvencije<br>b(k)*n | Stvarne<br>Proporcije<br>p(k) | Benfordove<br>proporcije<br>b(k) | Z - vrijednost      |
|--------------|--------------------------------|------------------------------------|-------------------------------|----------------------------------|---------------------|
| 1            | 12989                          | 12427,387                          | 0,314602659                   | 0,3010                           | <b>6,025715915</b>  |
| 2            | 7368                           | 7266,512                           | 0,17845811                    | 0,1760                           | 1,311559781         |
| 3            | 5113                           | 5160,875                           | 0,123840434                   | 0,1250                           | -0,712431462        |
| 4            | 4062                           | 3963,552                           | 0,098384479                   | 0,0960                           | 1,644676179         |
| 5            | 3207                           | 3261,673                           | 0,077675782                   | 0,0790                           | -0,997522914        |
| 6            | 2594                           | 2766,229                           | 0,062828493                   | 0,0670                           | <b>-3,39016935</b>  |
| 7            | 2215                           | 2394,646                           | 0,053648848                   | 0,0580                           | <b>-3,782434706</b> |
| 8            | 1970                           | 2105,637                           | 0,047714777                   | 0,0510                           | <b>-3,034263673</b> |
| 9            | 1769                           | 1899,202                           | 0,042846417                   | 0,0460                           | <b>-3,058847943</b> |
| TOTAL<br>(n) | 41287                          |                                    | 1                             | 1                                |                     |

Izvor: istraživanje autora

**Grafikon 1: Stvarne i očekivane frekvencije znamenki na prvoj brojevnoj poziciji u iznosima neto dobiti.**



Izvor: istraživanje autora



Hi-kvadrat vjerojatnost iznosi 0,000000000% što znači da se stvarne i očekivane frekvencije znamenki ne podudaraju u dovoljnoj mjeri. Iako vidimo (*Grafikon 1.*) mala odstupanja između stvarnih i očekivanih frekvencija kod svih znamenki, nalazimo statistički značajno odstupanje od Benfordove distribucije kod znamenki 1 (više nego što je očekivano), 6,7,8 i 9 kojih ima manje nego što je očekivano u iznosima neto dobiti što ukazuje na zaokruživanje prve znamenke i potvrđuje hipotezu vezano za dobit.

U *Tablici 4.* i na *Grafikonu 2.* vidimo rezultate za drugu brojevnju poziciju u iznosima neto dobiti.


**Tablica 4: Frekvencije i proporcije znamenki na drugoj brojevnoj poziciji u iznosima neto dobiti**

| Znamenka     | Stvarne<br>Frekvencije<br>f(k) | Očekivane<br>frekvencije<br>b(k)*n | Stvarne<br>Proporcije<br>p(k) | Benfordove<br>proporcije<br>b(k) | Z - vrijednost      |
|--------------|--------------------------------|------------------------------------|-------------------------------|----------------------------------|---------------------|
| 0            | 5307                           | 4942,0539                          | 0,12853925                    | 0,1197                           | <b>5,532986839</b>  |
| 1            | 4776                           | 4702,5893                          | 0,115678058                   | 0,1139                           | 1,137233047         |
| 2            | 4561                           | 4492,0256                          | 0,110470608                   | 0,1088                           | 1,090132359         |
| 3            | 4227                           | 4306,2341                          | 0,102380895                   | 0,1043                           | -1,275798315        |
| 4            | 4031                           | 4141,0861                          | 0,097633638                   | 0,1003                           | -1,803542978        |
| 5            | 3909                           | 3992,4529                          | 0,094678712                   | 0,0967                           | -1,389650306        |
| 6            | 3848                           | 3856,2058                          | 0,09320125                    | 0,0934                           | -0,138781945        |
| 7            | 3771                           | 3732,3448                          | 0,091336256                   | 0,0904                           | 0,66342498          |
| 8            | 3469                           | 3616,7412                          | 0,084021605                   | 0,0876                           | <b>-2,57187743</b>  |
| 9            | 3388                           | 3509,395                           | 0,082059728                   | 0,0850                           | <b>-2,142269605</b> |
| TOTAL<br>(n) | 41287                          |                                    | 1                             | 1                                |                     |

Izvor: istraživanje autora

Hi-kvadrat vjerojatnost iznosi 0,00006% što znači da je podudarnost stvarnih i očekivanih frekvencija vrlo mala. Značajna odstupanja od Benfordove distribucije zastupljena su kod znamenke 0 (više nego što je očekivano) i kod znamenki 8 i 9 (manje nego je očekivano) što potvrđuje ovu hipotezu.

**Grafikon 2: Stvarne i očekivane frekvencije znamenki na drugoj brojevnoj poziciji u iznosima neto dobiti**



Izvor: istraživanje autora


U Tablici 5. i na Grafikonu 3. vidimo rezultate za prvu brojevnu poziciju u iznosima gubitaka.

**Tablica 5: Frekvencije i proporcije znamenki na prvoj brojevnoj poziciji u iznosima gubitaka**

| Znamenka     | Stvarne<br>Frekvencije<br>$f(k)$ | Očekivane<br>frekvencije<br>$b(k)*n$ | Stvarne<br>Proporcije<br>$p(k)$ | Benfordove<br>proporcije<br>$b(k)$ | Z - vrijednost      |
|--------------|----------------------------------|--------------------------------------|---------------------------------|------------------------------------|---------------------|
| 1            | 7481                             | 7212,261                             | 0,312216                        | 0,3010                             | <b>3,784917273</b>  |
| 2            | 4252                             | 4217,136                             | 0,177455                        | 0,1760                             | 0,591431979         |
| 3            | 2884                             | 2995,125                             | 0,120362                        | 0,1250                             | <b>-2,170702325</b> |
| 4            | 2341                             | 2300,256                             | 0,0977                          | 0,0960                             | 0,893493427         |
| 5            | 1865                             | 1892,919                             | 0,077835                        | 0,0790                             | -0,668657974        |
| 6            | 1576                             | 1605,387                             | 0,065774                        | 0,0670                             | -0,759319512        |
| 7            | 1316                             | 1389,738                             | 0,054923                        | 0,0580                             | <b>-2,037977741</b> |
| 8            | 1173                             | 1222,011                             | 0,048955                        | 0,0510                             | -1,439205798        |
| 9            | 1073                             | 1102,206                             | 0,044781                        | 0,0460                             | -0,900671682        |
| TOTAL<br>(n) | 23961                            |                                      | 1                               | 1,00                               |                     |

Izvor: istraživanje autora

**Grafikon 3: Stvarne i očekivane frekvencije znamenki na prvoj brojevnoj poziciji u iznosima gubitaka**



Izvor: istraživanje autora

Hi-kvadrat vjerojatnost iznosi samo 0,37% što znači da se stvarne i očekivane frekvencije znamenki na prvoj brojevnoj poziciji podudaraju u vrlo maloj mjeri. Vidimo (*Grafikon 3.*) da postoje odstupanja kod svih znamenki na prvoj brojevnoj poziciji u iznosima gubitaka.

Međutim, samo je odstupanje znamenki 1 kojih ima više nego je očekivano i znamenki 3 i 7 kojih ima manje nego je očekivano statistički značajno.


U *Tablici 6.* i na *Grafikonu 4.* vidimo rezultate za drugu brojevnju poziciju u iznosima gubitaka.

**Tablica 6: Frekvencije i proporcije znamenki na drugoj brojevnoj poziciji u iznosima gubitaka**

| Znamenka            | Stvarne<br>Frekvencije<br>f(k) | Očekivane<br>frekvencije<br>b(k)*n | Stvarne<br>Proporcije<br>p(k) | Benfordove<br>proporcije<br>b(k) | Z - vrijednost     |
|---------------------|--------------------------------|------------------------------------|-------------------------------|----------------------------------|--------------------|
| 0                   | 2969                           | 2868,132                           | 0,12391                       | 0,1197                           | <b>2,007427206</b> |
| 1                   | 2674                           | 2729,158                           | 0,111598                      | 0,1139                           | -1,121636215       |
| 2                   | 2552                           | 2606,957                           | 0,106506                      | 0,1088                           | -1,140162967       |
| 3                   | 2560                           | 2499,132                           | 0,10684                       | 0,1043                           | 1,286503525        |
| 4                   | 2313                           | 2403,288                           | 0,096532                      | 0,1003                           | -1,941689042       |
| 5                   | 2337                           | 2317,029                           | 0,097533                      | 0,0967                           | 0,436540583        |
| 6                   | 2270                           | 2237,957                           | 0,094737                      | 0,0934                           | 0,71136744         |
| 7                   | 2145                           | 2166,074                           | 0,08952                       | 0,0904                           | -0,474780975       |
| 8                   | 2126                           | 2098,984                           | 0,088728                      | 0,0876                           | 0,617348386        |
| 9                   | 2015                           | 2036,685                           | 0,084095                      | 0,0850                           | -0,502327492       |
| <b>TOTAL</b><br>(n) | 23961                          |                                    | 1                             | 1,00                             |                    |

Izvor: istraživanje autora

**Grafikon 4: Stvarne i očekivane frekvencije znamenki na drugoj brojevnoj poziciji u iznosima gubitaka**



Izvor: istraživanje autora

Hi-kvadrat vjerojatnost iznosi samo 20,72% što znači da je relativno mala podudarnost stvarnih i očekivanih frekvencija znamenki na drugoj brojevnoj poziciji. Vidimo (*Grafikon 4.*) da na drugoj brojevnoj poziciji u iznosima gubitaka postoje veća odstupanja samo kod znamenke 0.

**Na temelju dobivenih rezultata istraživanja, možemo zaključiti da postoji prisutnost računovodstvenih kozmetičkih manipulacija na europskom tržištu kapitala kod obe brojeve pozicije kako za iznose dobiti tako i za iznose gubitka, tj. da postoje statistički značajna odstupanja od Benfordove distribucije. Dakle, rezultati su u skladu sa prethodnim istraživanjima i podržavanju postavljene hipoteze.**

Da bi testirali drugu pomoćnu hipotezu dijelimo ukupan uzorak na razvijena i manje razvijena tržišta kapitala. Podijela je napravljena na osnovu makroekonomskih pokazatelja kao što su

stopa rasta BDP-a, inflacija, postotak nezaposlenosti i javni dug koje je objavila Europska komisija. Među razvijene zemlje svrstane su Njemačka, Poljska, Francuska, Švedska i Velika Britanija iz razloga što im je ukupan dojam bolji od ostalih zemalja iako nisu bolje u svim segmentima kao npr. Francuska koja ima manju stopu rasta BDP-a od Španjolske ali zato i duplo manju stopu nezaposlenosti. Među manje razvijene zemlje svrstane Hrvatska, Italija, Španjolska, Bugarska i Rumunjska.

U *Tablici 7.* vidimo podatke o makroekonomskim pokazateljima razvijenih i manje razvijenih zemalja za 2015. godinu.

**Tablica 7: Makroekonomski pokazatelji razvijenih i manje razvijenih zemalja za 2015.**

| Zemlja           | Rast BDP-a (%) | Nezaposlenost (%) | Inflacija (%) | Bruto javni dug (%) |
|------------------|----------------|-------------------|---------------|---------------------|
| Njemačka         | 1,7            | 4,6               | 0,1           | 71,2                |
| Poljska          | 3,6            | 7,5               | -0,7          | 51,3                |
| Francuska        | 1,2            | 10,4              | 0,1           | 95,8                |
| Švedska          | 4,1            | 7,4               | 0,7           | 43,4                |
| Velika Britanija | 2,3            | 5,3               | 0,0           | 89,2                |
| Hrvatska         | 1,6            | 16,3              | -0,3          | 86,7                |
| Italija          | 0,8            | 11,9              | 0,1           | 132,7               |
| Španjolska       | 3,2            | 22,1              | -0,6          | 99,2                |
| Bugarska         | 3,0            | 9,2               | -1,1          | 26,7                |
| Rumunjska        | 3,8            | 6,8               | -0,4          | 38,4                |

Izvor: istraživanje autora na temelju podataka koje je objavila Europska komisija na stranici [http://ec.europa.eu/economy\\_finance/eu/countries/index\\_en.htm](http://ec.europa.eu/economy_finance/eu/countries/index_en.htm) [27.08.2016.]

U *Tablici 8.* i na *Grafikonu 5.* vidimo frekvencije i proporcije znamenki na prvoj brojevnoj poziciji u iznosima neto dobiti na razvijenim tržištima kapitala.

**Tablica 8: Frekvencije i proporcije znamenki na prvoj brojevnoj poziciji u iznosima neto dobiti (razvijena tržišta kapitala)**


| Znamenka     | Stvarne<br>Frekvencije<br>f(k) | Očekivane<br>frekvencije<br>b(k)*n | Stvarne<br>Proporcije<br>p(k) | Benfordove<br>proporcije<br>b(k) | Z - vrijednost     |
|--------------|--------------------------------|------------------------------------|-------------------------------|----------------------------------|--------------------|
| 1            | 6341                           | 6400,765                           | 0,29819                       | 0,3010                           | -0,893495552       |
| 2            | 3750                           | 3742,64                            | 0,176346                      | 0,1760                           | 0,132533352        |
| 3            | 2696                           | 2658,125                           | 0,126781                      | 0,1250                           | 0,785345781        |
| 4            | 2189                           | 2041,44                            | 0,102939                      | 0,0960                           | <b>3,434916002</b> |
| 5            | 1695                           | 1679,935                           | 0,079708                      | 0,0790                           | 0,38299498         |
| 6            | 1409                           | 1424,755                           | 0,066259                      | 0,0670                           | -0,432123108       |
| 7            | 1181                           | 1233,37                            | 0,055537                      | 0,0580                           | -1,536421699       |
| 8            | 1069                           | 1084,515                           | 0,05027                       | 0,0510                           | -0,483616258       |
| 9            | 935                            | 978,19                             | 0,043969                      | 0,0460                           | -1,413830699       |
| TOTAL<br>(n) | 21265                          |                                    |                               |                                  |                    |

Izvor: istraživanje autora

Hi-kvadrat vjerojatnost iznosi 3,65% što znači da je podudarnost stvarnih i očekivanih frekvencija znamenki nije na zadovoljavajućoj razini. Za razvijene zemlje nalazimo odstupanje od Benfordove distribucije samo za znamenku 4 koja je iznad Z – vrijednosti 1.96.



**Grafikon 5: Stvarne i očekivane frekvencije znamenki na prvoj brojevnoj poziciji u iznosima neto dobiti (razvijena tržišta kapitala)**



Izvor: istraživanje autora


U *Tablici 9.* i na *Grafikonu 6.* vidimo rezultate za drugu brojevnu poziciju u iznosima neto dobiti.

**Tablica 9: Frekvencije i proporcije znamenki na drugoj brojevnoj poziciji u iznosima neto dobiti (razvijena tržišta kapitala)**

| Znamenka     | Stvarne<br>Frekvencije<br>$f(k)$ | Očekivane<br>frekvencije<br>$b(k)*n$ | Stvarne<br>Proporcije<br>$p(k)$ | Benfordove<br>proporcije<br>$b(k)$ | Z - vrijednost      |
|--------------|----------------------------------|--------------------------------------|---------------------------------|------------------------------------|---------------------|
| 0            | 2753                             | 2545,421                             | 0,129462                        | 0,1197                             | <b>4,385199358</b>  |
| 1            | 2478                             | 2422,084                             | 0,11653                         | 0,1139                             | 1,206991067         |
| 2            | 2369                             | 2313,632                             | 0,111404                        | 0,1088                             | 1,219337993         |
| 3            | 2169                             | 2217,94                              | 0,101999                        | 0,1043                             | -1,098002662        |
| 4            | 2029                             | 2132,88                              | 0,095415                        | 0,1003                             | <b>-2,371361859</b> |
| 5            | 2013                             | 2056,326                             | 0,094663                        | 0,0967                             | -1,005267513        |
| 6            | 1970                             | 1986,151                             | 0,09264                         | 0,0934                             | -0,380614587        |
| 7            | 1918                             | 1922,356                             | 0,090195                        | 0,0904                             | -0,104170737        |
| 8            | 1792                             | 1862,814                             | 0,08427                         | 0,0876                             | -1,717677954        |
| 9            | 1774                             | 1807,525                             | 0,083423                        | 0,0850                             | -0,824358429        |
| TOTAL<br>(n) | 21265                            |                                      |                                 |                                    |                     |

Izvor: istraživanje autora

**Grafikon 6: Stvarne i očekivane frekvencije znamenki na drugoj brojevnoj poziciji u iznosima neto dobiti (razvijena tržišta kapitala)**



Izvor: istraživanje autora

Hi-kvadrat vjerojatnost iznosi 0,04% što znači da podudarnost stvarnih i očekivanih frekvencija znamenki vrlo mala i nije zadovoljavajuća. Statistički značajna odstupanja od Benfordove distribucije nalazimo kod znamenke 0 koje ima više nego je to očekivano i kod znamenke 4 koje ima manje nego je to očekivano.


U *Tablici 10.* i na *Grafikonu 7.* vidimo rezultate za prvu brojevnu poziciju u iznosima gubitaka.

**Tablica 10: Frekvencije i proporcije znamenki na prvoj brojevnoj poziciji u iznosima gubitaka (razvijena tržišta kapitala)**

| Znamenka     | Stvarne<br>Frekvencije<br>f(k) | Očekivane<br>frekvencije<br>b(k)*n | Stvarne<br>Proporcije<br>p(k) | Benfordove<br>proporcije<br>b(k) | Z - vrijednost     |
|--------------|--------------------------------|------------------------------------|-------------------------------|----------------------------------|--------------------|
| 1            | 3329                           | 3347,722                           | 0,299317                      | 0,3010                           | -0,387024947       |
| 2            | 1909                           | 1957,472                           | 0,171642                      | 0,1760                           | -1,206922974       |
| 3            | 1358                           | 1390,25                            | 0,1221                        | 0,1250                           | -0,924653974       |
| 4            | 1130                           | 1067,712                           | 0,1016                        | 0,0960                           | <b>2,004901816</b> |
| 5            | 877                            | 878,638                            | 0,078853                      | 0,0790                           | -0,057580985       |
| 6            | 761                            | 745,174                            | 0,068423                      | 0,0670                           | 0,600207603        |
| 7            | 622                            | 645,076                            | 0,055925                      | 0,0580                           | -0,936115932       |
| 8            | 589                            | 567,222                            | 0,052958                      | 0,0510                           | 0,938660092        |
| 9            | 547                            | 511,612                            | 0,049182                      | 0,0460                           | 1,601811731        |
| TOTAL<br>(n) | 11122                          |                                    |                               |                                  |                    |

Izvor: istraživanje autora

**Grafikon 7: Stvarne i očekivane frekvencije znamenki na prvoj brojevnoj poziciji u iznosima gubitaka (razvijena tržišta kapitala)**



Izvor: istraživanje autora

Hi-kvadrat vjerojatnost iznosi 25,56% što znači da je mala podudarnost stvarnih i očekivanih frekvencija znamenki na prvoj brojevnoj poziciji. U iznosima gubitaka na prvoj brojevnoj poziciji, vidimo samo statistički značajno odstupanje znamenke 4 ( $Z=2,004$ ).


U *Tablici 11.* i na *Grafikonu 8.* vidimo rezultate za drugu brojevnju poziciju u iznosima gubitaka.

**Tablica 11: Frekvencije i proporcije znamenki na drugoj brojevnoj poziciji u iznosima gubitaka (razvijena tržišta kapitala)**

| Znamenka            | Stvarne<br>Frekvencije<br>f(k) | Očekivane<br>frekvencije<br>b(k)*n | Stvarne<br>Proporcije<br>p(k) | Benfordove<br>proporcije<br>b(k) | Z - vrijednost      |
|---------------------|--------------------------------|------------------------------------|-------------------------------|----------------------------------|---------------------|
| 0                   | 1348                           | 1331,303                           | 0,121201                      | 0,1197                           | 0,48772405          |
| 1                   | 1248                           | 1266,796                           | 0,11221                       | 0,1139                           | -0,561004235        |
| 2                   | 1198                           | 1210,074                           | 0,107714                      | 0,1088                           | -0,367657391        |
| 3                   | 1206                           | 1160,025                           | 0,108434                      | 0,1043                           | 1,426299171         |
| 4                   | 1046                           | 1115,537                           | 0,094048                      | 0,1003                           | <b>-2,194940136</b> |
| 5                   | 1098                           | 1075,497                           | 0,098723                      | 0,0967                           | 0,721958132         |
| 6                   | 1047                           | 1038,795                           | 0,094138                      | 0,0934                           | 0,267372311         |
| 7                   | 1002                           | 1005,429                           | 0,090092                      | 0,0904                           | -0,113381257        |
| 8                   | 986                            | 974,2872                           | 0,088653                      | 0,0876                           | 0,39284804          |
| 9                   | 943                            | 945,37                             | 0,084787                      | 0,0850                           | -0,080581786        |
| <b>TOTAL</b><br>(n) | 11122                          |                                    |                               |                                  |                     |

Izvor: istraživanje autora

**Grafikon 8: Stvarne i očekivane frekvencije znamenki na drugoj brojevnoj poziciji u iznosima gubitaka (razvijena tržišta kapitala)**



Izvor: istraživanje autora

Hi-kvadrat vjerojatnost iznosi 58,93% što znači da je podudarnost stvarnih i očekivanih frekvencija znamenki zadovoljavajuća. U iznosima gubitaka na drugoj brojevnoj poziciji postoji odstupanje samo kod znamenke 4 koje ima manje nego je očekivano.


U *Tablici 12.* i na *Grafikonu 9.* vidimo rezultate za prvu brojevnu poziciju u iznosima neto dobiti.

**Tablica 12: Frekvencije i proporcije znamenki na prvoj brojevnoj poziciji u iznosima neto dobiti (manje razvijena tržišta kapitala)**

| Znamenka     | Stvarne<br>Frekvencije<br>$f(k)$ | Očekivane<br>frekvencije<br>$b(k)*n$ | Stvarne<br>Proporcije<br>$p(k)$ | Benfordove<br>proporcije<br>$b(k)$ | Z - vrijednost      |
|--------------|----------------------------------|--------------------------------------|---------------------------------|------------------------------------|---------------------|
| 1            | 2927                             | 2672,88                              | 0,329617                        | 0,3010                             | <b>5,879095678</b>  |
| 2            | 1612                             | 1562,88                              | 0,181532                        | 0,1760                             | 1,368774594         |
| 3            | 1059                             | 1110                                 | 0,119257                        | 0,1250                             | -1,636457234        |
| 4            | 852                              | 852,48                               | 0,095946                        | 0,0960                             | -0,017290793        |
| 5            | 666                              | 701,52                               | 0,075                           | 0,0790                             | -1,39740764         |
| 6            | 519                              | 594,96                               | 0,058446                        | 0,0670                             | <b>-3,224038727</b> |
| 7            | 477                              | 515,04                               | 0,053716                        | 0,0580                             | -1,727008906        |
| 8            | 384                              | 452,88                               | 0,043243                        | 0,0510                             | <b>-3,32252656</b>  |
| 9            | 384                              | 408,48                               | 0,043243                        | 0,0460                             | -1,240086065        |
| TOTAL<br>(n) | 8880                             |                                      |                                 |                                    |                     |

Izvor: istraživanje autora

**Grafikon 9: Stvarne i očekivane frekvencije znamenki na prvoj brojevnoj poziciji u iznosima neto dobiti (manje razvijena tržišta kapitala)**



Izvor: istraživanje autora

Hi-kvadrat vjerojatnost iznosi 0,0000006% što znači da je podudarnost stvarnih i očekivanih frekvencija na jako maloj razini. Na prvoj brojevnoj poziciji u iznosima neto dobiti vidimo odstupanja kod znamenki 1 (više nego je očekivano), 6 i 8 kojih je manje nego je očekivano.

U *Tablici 13.* i na *Grafikonu 10.* vidimo rezultate za drugu brojevnju poziciju u iznosima neto dobiti.


**Tablica 13: Frekvencije i proporcije znamenki na drugoj brojevnoj poziciji u iznosima neto dobiti (manje razvijena tržišta kapitala)**

| Znamenka            | Stvarne<br>Frekvencije<br>f(k) | Očekivane<br>frekvencije<br>b(k)*n | Stvarne<br>Proporcije<br>p(k) | Benfordove<br>proporcije<br>b(k) | Z - vrijednost     |
|---------------------|--------------------------------|------------------------------------|-------------------------------|----------------------------------|--------------------|
| 0                   | 1134                           | 1062,936                           | 0,127703                      | 0,1197                           | <b>2,323168659</b> |
| 1                   | 1016                           | 1011,432                           | 0,114414                      | 0,1139                           | 0,152586595        |
| 2                   | 955                            | 966,144                            | 0,107545                      | 0,1088                           | -0,379780432       |
| 3                   | 912                            | 926,184                            | 0,102703                      | 0,1043                           | -0,492457548       |
| 4                   | 899                            | 890,664                            | 0,101239                      | 0,1003                           | 0,29447735         |
| 5                   | 806                            | 858,696                            | 0,090766                      | 0,0967                           | -1,892090588       |
| 6                   | 819                            | 829,392                            | 0,09223                       | 0,0934                           | -0,378975696       |
| 7                   | 848                            | 802,752                            | 0,095495                      | 0,0904                           | 1,674493491        |
| 8                   | 743                            | 777,888                            | 0,083671                      | 0,0876                           | -1,309558487       |
| 9                   | 748                            | 754,8                              | 0,084234                      | 0,0850                           | -0,258751228       |
| <b>TOTAL</b><br>(n) | 8880                           |                                    |                               |                                  |                    |

Izvor: istraživanje autora



**Grafikon 10: Stvarne i očekivane frekvencije znamenki na drugoj brojevnoj poziciji u iznosima neto dobiti (manje razvijena tržišta kapitala)**



Izvor: istraživanje autora

Hi-kvadrat vjerojatnost iznosi 17,49% što znači da je mala podudarnost stvarnih i očekivanih frekvencija znamenki. Na drugoj brojevnoj poziciji, unatoč odstupanjima gotovo svih znamenki ne nalazimo nijedno statistički značajno odstupanje osim znamenke 0, tj. većina Z-vrijednosti su ispod granične vrijednosti. Vidimo da imamo samo višak nula.


U *Tablici 14.* i na *Grafikonu 11.* vidimo rezultate za prvu brojevnju poziciju u iznosima gubitaka.

**Tablica 14: Frekvencije i proporcije znamenki na prvoj brojevnoj poziciji u iznosima gubitaka (manje razvijena tržišta kapitala)**

| Znamenka     | Stvarne<br>Frekvencije<br>$f(k)$ | Očekivane<br>frekvencije<br>$b(k)*n$ | Stvarne<br>Proporcije<br>$p(k)$ | Benfordove<br>proporcije<br>$b(k)$ | Z - vrijednost      |
|--------------|----------------------------------|--------------------------------------|---------------------------------|------------------------------------|---------------------|
| 1            | 1474                             | 1318,681                             | 0,336453                        | 0,3010                             | <b>5,115830225</b>  |
| 2            | 811                              | 771,056                              | 0,185118                        | 0,1760                             | 1,584692442         |
| 3            | 508                              | 547,625                              | 0,115955                        | 0,1250                             | -1,810187725        |
| 4            | 380                              | 420,576                              | 0,086738                        | 0,0960                             | <b>-2,080955406</b> |
| 5            | 349                              | 346,099                              | 0,079662                        | 0,0790                             | 0,162486671         |
| 6            | 272                              | 293,527                              | 0,062086                        | 0,0670                             | -1,300824359        |
| 7            | 227                              | 254,098                              | 0,051815                        | 0,0580                             | -1,751504122        |
| 8            | 184                              | 223,431                              | 0,042                           | 0,0510                             | <b>-2,707902171</b> |
| 9            | 176                              | 201,526                              | 0,040173                        | 0,0460                             | -1,840954416        |
| TOTAL<br>(n) | 4381                             |                                      |                                 |                                    |                     |

Izvor: istraživanje autora

**Grafikon 11: Stvarne i očekivane frekvencije znamenki na prvoj brojevnoj poziciji u iznosima gubitaka (manje razvijena tržišta kapitala)**



Izvor: istraživanje autora

Hi-kvadrat vjerojatnost iznosi 0,00015% što znači da je podudarnost stvarnih i očekivanih frekvencija znamenki na vrlo maloj razini. Statistički značajno odstupanje znamenki nalazimo na broju 1 (više nego je očekivano) i na brojevima 4 i 8 kojih je manje nego je očekivano.

U *Tablici 15.* i na *Grafikonu 12.* vidimo rezultate za drugu brojevnju poziciju u iznosima gubitaka.


**Tablica 15: Frekvencije i proporcije znamenki na drugoj brojevnoj poziciji u iznosima gubitaka (manje razvijena tržišta kapitala)**

| Znamenka     | Stvarne<br>Frekvencije<br>$f(k)$ | Očekivane<br>frekvencije<br>$b(k)*n$ | Stvarne<br>Proporcije<br>$p(k)$ | Benfordove<br>proporcije<br>$b(k)$ | Z - vrijednost     |
|--------------|----------------------------------|--------------------------------------|---------------------------------|------------------------------------|--------------------|
| 0            | 560                              | 524,4057                             | 0,127825                        | 0,1197                             | <b>1,656652437</b> |
| 1            | 499                              | 498,9959                             | 0,113901                        | 0,1139                             | 0,000194982        |
| 2            | 472                              | 476,6528                             | 0,107738                        | 0,1088                             | -0,225748941       |
| 3            | 454                              | 456,9383                             | 0,103629                        | 0,1043                             | -0,145239942       |
| 4            | 436                              | 439,4143                             | 0,099521                        | 0,1003                             | -0,171717962       |
| 5            | 435                              | 423,6427                             | 0,099292                        | 0,0967                             | 0,580576201        |
| 6            | 413                              | 409,1854                             | 0,094271                        | 0,0934                             | 0,198052844        |
| 7            | 379                              | 396,0424                             | 0,08651                         | 0,0904                             | -0,897913884       |
| 8            | 385                              | 383,7756                             | 0,087879                        | 0,0876                             | 0,065432272        |
| 9            | 348                              | 372,385                              | 0,079434                        | 0,0850                             | -1,321040473       |
| TOTAL<br>(n) | 4381                             |                                      |                                 |                                    |                    |

Izvor: istraživanje autora

Hi-kvadrat vjerojatnost iznosi 81,83% što znači da je podudarnost stvarnih i očekivanih frekvencija znamenki vrlo visoka. Statistički značajno odstupanja od Benfordove distribucije ne pojavljuje se kod nijedne znamenke.

**Grafikon 12: Stvarne i očekivane frekvencije znamenki na drugoj brojevnoj poziciji u iznosima gubitaka (manje razvijena tržišta kapitala)**



Izvor: istraživanje autora

Na temelju dobivenih rezultata istraživanja, možemo zaključiti da nema razlike u rezultatima razvijenih i manje razvijenih tržišta kapitala. Vrijednosti Hi-kvadrat testa veće su samo kod druge znamenke u pozicijama gubitka i to kod razvijenih i manje razvijenih tržišta kapitala. Dakle, rezultati podržavaju postavljenu hipotezu.

## 6. ZAKLJUČAK

U ovom istraživanju obuhvaćeno je razdoblje od 2005. do 2014. godine kako bi istražili da li se manipulira iznosima neto financijskih rezultata primjenom Benfordove zakonitosti.

Pošto smo u iznosima neto dobiti i neto gubitka za period od 10 godina našli statistički značajna odstupanja zaključujemo da istraživanje odgovara prethodnim istraživanjima te se prihvaćaju postavljene hipoteze. Vrijednost Hi-kvadrat testa (0,000% i 0,00004%) je u potpunosti ne zadovoljavajuća kod iznosa neto dobiti što znači da se stvarne frekvencije ne podudaraju sa očekivanim frekvencijama u dovoljnoj mjeri. Kod iznosa gubitaka situacija je nešto drugačija, vrijednost Hi-kvadrat testa (0,37% i 20,72%) je također ne zadovoljavajuća te se ne podudara s očekivanim frekvencijama ali u manjoj mjeri nego što je to kod iznosa neto dobiti.

Za potrebe druge pomoćne hipoteze prvi uzorak podijeljen je na razvijena i manje razvijena tržišta kapitala odnosno na razvijene i manje razvijene zemlje. Kod razvijenih zemalja nalazimo statistički značajna odstupanja od Benfordove distribucije kod iznosa neto dobiti i gubitka. Vrijednosti Hi-kvadrat testa iznose (3,65% i 25,56), osim kod iznosa gubitka na drugoj bojevnoj poziciji gdje je vrijednost Hi-kvadrat testa iznosila zadovoljavajućih 58,93%. Kod manje razvijenih zemalja situacija je dosta slična, odnosno postoje statistički značajna odstupanja od Benfordove distribucije kod iznosa neto dobiti i gubitka. Vrijednosti Hi-kvadrat testa iznose (0,000% i 0,0001%), osim kod iznosa na drugoj brojevnoj poziciji gdje je vrijednost Hi-kvadrat testa iznosila 81,83%.

Zaključno, može se ustvrditi kako su na generalnom nivou (putem Hi kvadrat testa), pronađena značajna odstupanja od Benfordovog zakona te se po tome ovo istraživanje ne razlikuje puno od prethodnih istraživanja. Također kod druge hipoteze možemo doći do zaključka kako ne postoji značajna razlika u korištenju kozmetičkih računovodstvenih manipulacija između razvijenih i manje razvijenih tržišta kapitala što nam govori da ni razvijenija tržišta kapitala sa uređenijim institucionalnim okvirima nisu imuna na tendencije menadžmenta u korištenju kozmetičkih računovodstvenih manipulacija.

## **SAŽETAK**

Svrha i cilj ovog rada bila je istražiti teorijski proces financijskog izvještavanja, s posebnim naglaskom na kozmetičke računovodstvene manipulacije (proces zaokruživanja iznosa neto financijskih rezultata kako bi se postigla ključna kognitivna referentna točka  $N \times 10^k$ ), Benfordov zakon i mogućnost njegove primjene u ovom području. Osim toga, cilj rada bio je empirijski istražiti da li se manipulira računovodstvenim podacima na europskom tržištu kapitala odnosno neto financijskim rezultatima poduzeća koristeći Benfordov zakon. U ovom istraživanju testirali smo iznose neto financijskih rezultata poduzeća iz deset europskih zemalja kako razvijenih tako i manje razvijenih tržišta kapitala. S obzirom na rezultate istraživanja možemo zaključiti kako postoje značajna odstupanja od Benfordove zakonitosti, odnosno ovo istraživanje se po tome ne razlikuje puno od prethodnih. Također rezultati istraživanja pokazali su kako su kozmetičke računovodstvene manipulacije podjednako zastupljene i u razvijenim i u manje razvijenim tržištima kapitala.

## **SUMMARY**

The purpose and aim of this paper was to theoretically investigate the financial reporting process, with special focus on cosmetic accounting manipulations (process of rounding earnings numbers (net income) to achieve key cognitive reference points represented by  $N \times 10^k$ ), Benford's law and the possibility of its application in this area. In addition, the goal of the paper was to empirically investigate whether manipulating the accounting data in the European capital market namely the net financial results of companies using Benford's law. In this study we examined distributions of digits earnings numbers companies for sample of ten European countries with developed and less developed capital markets. Considering the test results we found a statistically significant deviation of Benford's law so this study is correspond to previous research. Also the test results showed that there is no difference between developed and less developed capital markets in Europe.

## LITERATURA

1. Aljinović Barać, Ž., Klepo, T. (2006): Features of accounts manipulations in Croatia, Zbornik radova Ekonomskog fakulteta Rijeka., Vol. 24, Sv. 2, str. 273-290.
2. Carslaw, C. (1988): Anomalies in income numbers: evidence of goal oriented behaviour, The Accounting review, Vol. 63, No. 2, str. 321-327.
3. Copeland, R. (1968): Income smoothing, Journal of Accounting Research, Vol. 6, str. 101-116.
4. Fengyi, Sheng – Fu, W. (2014): Comparison of cosmetic earnings management for the developed markets and emerging markets: Some empirical evidence from the United States and Taiwan, Vol. 36, str. 466-473.
5. Gayer, D., Drachler, C. (2014): Detecting cosmetic dept management using Benford's law, Vol. 30, No. 5.
6. Guan, L. et. al. (2006): Auditing, integral approach to quarterly reporting, and cosmetic earnings management. Managerial Auditing Journal, Vol. 21, No. 6, str. 569–581.
7. Guan, L., Aono, JY. (2008): The Impact of Sarbanes-Oxley Act on Cosmetic Earnings Management. Research in Accounting Regulation, Vol. 20, str. 205-215.
8. Gulin, D. (2002): Manipulacije na financijskim tržištima i njihov utjecaj na financijske izvještaje, Računovodstvo, financije i revizija u suvremenim gospodarskim uvjetima, XXXVII. simpozij Pula, Zagreb, HZRF.
9. Griffiths I. (1986): Creative accounting: how to make your profits what you want them to be, Sidgwick & Jackson Ltd; 1st ed edition.
10. Kinnunen, J., Koskela, M. (2003): Who is Miss World in cosmetic earnings management? A cross-national comparison of small upward rounding of net income numbers among eighteen countries, Journal of International Accounting Research, Vol. 2, No. 2, str. 39-68.
11. Mead, H. et. al. (1938): The philosophy of the act, University of Chicago.
12. Narodne novine, (2016): Odbor za standarde financijskog izvještavanja, Narodne novine dd. Zagreb, broj 140.
13. Narodne novine, (2015): Zakon o računovodstvu, Narodne novine dd. Zagreb, broj 78.
14. Niskanen, J., Keloharju M. (2000): Earnings cosmetics in a tax-driven accounting environment: evidence from Finnish public firms, European Accounting Review, Vol. 9, No. 3., str. 443-452.
15. Novalija, S. (2011): Forenzičko računovodstvo i utjecaj kreativnog računovodstva na financijske izvještaje, Sveučilište u Tuzli, Ekonomski fakultet, str. 567-585.

16. Pivac, S. (2010): Statističke metode: e-nastavni materijali, Statističke metode, Ekonomski fakultet Split, Split.
17. Soltani B. (2009): Revizija, međunarodni pristup, Mate d.o.o., Zagreb.
18. Stojanović, V., Borowiecki K. (2015): Cosmetic earnings management and quarterly reporting: evidence from European companies, International Journal of Economics and Accounting, Vol. 6, No. 3.
19. Stolowy, H., Breton G. (2005): A framework for the classification of accounts manipulation, No. 708/2000.
20. Sweeney, P. (1994): Debt-covenant violations managers' accounting responses, Vol. 17, No. 3., str. 281-308
21. Thomas, K. (1989): Unusual patterns in reporting earnings, Vol. 64, No. 4., str. 737-787.
22. Thomas, E., Wilson J. (2012): Further evidence on the extent of cosmetic earnings management by U.S. firms, Academy of Accounting and Financial Studies Journal, Vol. 16, No. 3., str. 57-64.
23. Vidučić, Lj. (2004): Financijski menadžment, RriF Plus d.o.o., Zagreb.
24. Viljac, M. (2012): Primjena Benfordovog zakona u otkrivanju računovodstvenih manipulacija, Magistarski rad.
25. Vujević, I. (2004): Financijska analiza, Ekonomski fakultet Split, Split.
26. Zelenika, R. (2010): Metodologija i tehnika izrade znanstvenog i stručnog djela, Ekonomski fakultet Sveučilišta u Rijeci, Rijeka.

## **POPIS SLIKA:**

|                                                                                             |    |
|---------------------------------------------------------------------------------------------|----|
| <b>Slika 1:</b> Trokut prijevara.....                                                       | 23 |
| <b>Slika 2:</b> Ugladivanje trenda zarada.....                                              | 25 |
| <b>Slika 3:</b> Relativne frekvencije prvih znamenaka u različitim skupinama podataka ..... | 33 |
| <b>Slika 4:</b> Histogram .....                                                             | 35 |
| <b>Slika 5:</b> Vjerojatnost pojavljivanja brojeva na prvih pet brojevnih pozicija .....    | 39 |

## **POPIS TABLICA:**



|                                                                                                                                                  |    |
|--------------------------------------------------------------------------------------------------------------------------------------------------|----|
| <b>Tablica 1:</b> Frekvencije pojavljivanja prve znamenke u broju stanovnika.....                                                                | 34 |
| <b>Tablica 2:</b> Logaritamska skala .....                                                                                                       | 35 |
| <b>Tablica 3:</b> Frekvencije i proporcije znamenki na prvoj brojevnoj poziciji u iznosima.....                                                  | 40 |
| <b>Tablica 4:</b> Frekvencije i proporcije znamenki na drugoj brojevnoj poziciji u iznosima neto dobiti.....                                     | 41 |
| <b>Tablica 5:</b> Frekvencije i proporcije znamenki na prvoj brojevnoj poziciji u iznosima gubitaka .....                                        | 43 |
| <b>Tablica 6:</b> Frekvencije i proporcije znamenki na drugoj brojevnoj poziciji u iznosima gubitaka .....                                       | 45 |
| <b>Tablica 7:</b> Makroekonomski pokazatelji razvijenih i manje razvijenih zemalja.....                                                          | 47 |
| <b>Tablica 8:</b> Frekvencije i proporcije znamenki na prvoj brojevnoj poziciji u iznosima neto dobiti (razvijena tržišta kapitala).....         | 48 |
| <b>Tablica 9:</b> Frekvencije i proporcije znamenki na drugoj brojevnoj poziciji u iznosima neto dobiti (razvijena tržišta kapitala).....        | 50 |
| <b>Tablica 10:</b> Frekvencije i proporcije znamenki na prvoj brojevnoj poziciji u iznosima gubitaka (razvijena tržišta kapitala) .....          | 51 |
| <b>Tablica 11:</b> Frekvencije i proporcije znamenki na drugoj brojevnoj poziciji u iznosima gubitaka (razvijena tržišta kapitala).....          | 53 |
| <b>Tablica 12:</b> Frekvencije i proporcije znamenki na prvoj brojevnoj poziciji u iznosima neto dobiti (manje razvijena tržišta kapitala) ..... | 55 |
| <b>Tablica 13:</b> Frekvencije i proporcije znamenki na drugoj brojevnoj poziciji u iznosima neto dobiti (manje razvijena tržišta kapitala)..... | 56 |
| <b>Tablica 14:</b> Frekvencije i proporcije znamenki na prvoj brojevnoj poziciji u iznosima gubitaka (manje razvijena tržišta kapitala).....     | 58 |
| <b>Tablica 15:</b> Frekvencije i proporcije znamenki na drugoj brojevnoj poziciji u iznosima gubitaka (manje razvijena tržišta kapitala).....    | 59 |

## POPIS GRAFIKONA:

|                                                                                                                                                          |    |
|----------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| <b>Grafikon 1:</b> Stvarne i očekivane frekvencije znamenki na prvoj brojevnoj poziciji u iznosima neto dobiti.....                                      | 40 |
| <b>Grafikon 2:</b> Stvarne i očekivane frekvencije znamenki na drugoj brojevnoj poziciji u iznosima neto dobiti .....                                    | 42 |
| <b>Grafikon 3:</b> Stvarne i očekivane frekvencije znamenki na prvoj brojevnoj poziciji u iznosima gubitaka .....                                        | 44 |
| <b>Grafikon 4:</b> Stvarne i očekivane frekvencije znamenki na drugoj brojevnoj poziciji u iznosima gubitaka.....                                        | 46 |
| <b>Grafikon 5:</b> Stvarne i očekivane frekvencije znamenki na prvoj brojevnoj poziciji u iznosima neto dobiti (razvijena tržišta kapitala) .....        | 49 |
| <b>Grafikon 6:</b> Stvarne i očekivane frekvencije znamenki na drugoj brojevnoj poziciji u iznosima neto dobiti (razvijena tržišta kapitala) .....       | 50 |
| <b>Grafikon 7:</b> Stvarne i očekivane frekvencije znamenki na prvoj brojevnoj poziciji u iznosima gubitaka (razvijena tržišta kapitala) .....           | 52 |
| <b>Grafikon 8:</b> Stvarne i očekivane frekvencije znamenki na drugoj brojevnoj poziciji u iznosima gubitaka (razvijena tržišta kapitala) .....          | 54 |
| <b>Grafikon 9:</b> Stvarne i očekivane frekvencije znamenki na prvoj brojevnoj poziciji u iznosima neto dobiti (manje razvijena tržišta kapitala) .....  | 55 |
| <b>Grafikon 10:</b> Stvarne i očekivane frekvencije znamenki na drugoj brojevnoj poziciji u iznosima neto dobiti (manje razvijena tržišta kapitala)..... | 57 |
| <b>Grafikon 11:</b> Stvarne i očekivane frekvencije znamenki na prvoj brojevnoj poziciji u iznosima gubitaka (manje razvijena tržišta kapitala) .....    | 58 |
| <b>Grafikon 12:</b> Stvarne i očekivane frekvencije znamenki na drugoj brojevnoj poziciji u iznosima gubitaka (manje razvijena tržišta kapitala) .....   | 60 |